



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

**Soluções otimizadas para implantação de redes
militarizadas 4G/LTE com máxima cobertura e
mínima interferência**

Emerson de O. Antunes

Dissertação apresentada como requisito parcial para conclusão do
Mestrado Profissional em Computação Aplicada

Orientador

Prof. Dr. Geraldo Pereira Rocha Filho

Brasília
2022

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

dA636s de Oliveira Antunes, Emerson
Soluções otimizadas para implantação de redes
militarizadas 4G/LTE com máxima cobertura e mínima
interferência / Emerson de Oliveira Antunes; orientador
Geraldo Pereira Rocha Filho. -- Brasília, 2022.
61 p.

Dissertação (Mestrado - Mestrado Profissional em
Computação Aplicada) -- Universidade de Brasília, 2022.

1. Otimização de redes. 2. Otimização multiobjetivo. 3.
Planejamento de redes de telefonia. I. Pereira Rocha Filho,
Geraldo, orient. II. Título.



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Soluções otimizadas para implantação de redes militarizadas 4G/LTE com máxima cobertura e mínima interferência

Emerson de O. Antunes

Dissertação apresentada como requisito parcial para conclusão do
Mestrado Profissional em Computação Aplicada

Prof. Dr. Geraldo Pereira Rocha Filho (Orientador)
CIC/UnB

Prof. Dr. Jó Ueyama Prof. Dr. Lourenço Alves Pereira Jr.
Universidade de São Paulo Instituto Tecnológico de Aeronáutica

Prof. Dr. Marcelo Ladeira
Coordenador do Programa de Pós-graduação em Computação Aplicada

Brasília, 20 de Abril de 2022

Dedicatória

Dedico este trabalho à minha esposa, Lilian, por todo amor, paciência, apoio e dedicação, fundamentais nesta jornada para tornar realidade mais esse sonho.

Aos meus filhos Alisson e Laura, por compreenderem os momentos que estive ausente para me dedicar a este projeto.

Agradecimentos

Agradeço principalmente ao orientador e amigo Prof.Dr. Geraldo P. Rocha Filho pela confiança, paciência e humildade com que me acolheu nesta trajetória. Agradeço à equipe de coorientadores, Prof.Dr. Marcos F. Caetano, Prof.Dr. Marcelo A. Marotta, Profa. Dra. Aleteia Patricia Favacho de Araujo e Dr. Lucas Bondan, pelos ensinamentos e ideias enriquecedoras que alicerçaram esta pesquisa. Agradeço especialmente ao PPCA (Programa de Pós-Graduação em Computação Aplicada) e à UnB (Universidade de Brasília) por todo conhecimento e apoio ao longo desta trajetória acadêmica. Pela soma dos esforços de todos vocês é que concluo o Mestrado mais forte do que quando comecei.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), por meio do Acesso ao Portal de Periódicos.

Resumo

Este trabalho explora o problema de localização de cobertura máxima do Centro de Coordenação de Operações Móveis (CCOp Mv), que visa apoiar o comando operacional do Exército Brasileiro. Este problema consiste em selecionar as posições dos veículos, a sua quantidade necessária e a potência de transmissão para maximizar a área de cobertura e reduzir a interferência devido à sobreposição de sinais. Ressaltando-se que os veículos do CCOp Mv são equipados com Estações Transceptoras Base do sistema de rádio celular, do inglês *Base Transceiver Station* (BTS)s e destinam-se a prover a infraestrutura de comunicações nas áreas de operação das tropas terrestres. Por esta razão, foi proposta uma modelagem analítica baseada em Programação Linear Inteira Mista (PLIM) que orientou duas soluções de otimização: (i) E-ALLOCATOR – Exact ALLOCATiOn seRvice; e (ii) M-ALLOCATOR – Metaheuristic ALLOCATiOn seRvice. As soluções foram avaliadas em um cenário que emprega o CCOp Mv para dar suporte a uma operação de resgate baseada na tragédia ocorrida em janeiro de 2019 na cidade de Brumadinho-MG e comparadas com uma heurística. Os resultados da avaliação de desempenho mostram evidências de eficiência em termos de qualidade e economia de recursos das soluções propostas. Além disso, o E-ALLOCATOR provou ser adequado para uma baixa carga de trabalho na rede. Ao mesmo tempo, o M-ALLOCATOR é adequado para cenários com alta carga de trabalho, fornecendo soluções quase ótimas dentro do tempo computacional adequado para todas as instâncias do problema.

Palavras-chave: problema de localização de máxima cobertura, problema de localização, mínima interferência, cobertura 4G/LTE, comunicações críticas, otimização multi objetivo, rede militar em ambiente de catástrofe

Abstract

This work explores the maximal covering location problem of the Mobile Operations Coordination Center (CCOp Mv), which aims to support the operational command of the Brazilian Army. This problem consists of selecting vehicle positions, their required quantity and transmission power to maximize the coverage area and reduce interference due to overlapping signals. The CCOp Mv vehicles are equipped with *Base Transceiver Station* (BTS), and are intended to provide the communications infrastructure in the areas of operation of the ground troops. For this reason, analytical modeling based on the mixed-integer linear problem was proposed that guided two optimization solutions: (i) E-ALLOCATOR – Exact ALLOCATiOn seRvice; and (ii) M-ALLOCATOR – Metaheuristic ALLOCATiOn seRvice. The solutions were evaluated in a scenario that employs CCOp Mv to support a rescue operation based on the tragedy in January 2019 in Brumadinho-MG and compared with a heuristic. The performance evaluation results show evidence of efficiencies in terms of quality and resource savings of the proposed solutions. Furthermore, E-ALLOCATOR has been proven to be suitable for a low workload on the network. At the same time, M-ALLOCATOR is suitable for scenarios with a high workload providing almost optimal solutions within the adequate computational time for all problem instances.

Keywords: Maximal Covering Location Problem, location problem, minimum interference, 4G/LTE coverage, critical communications, multi objective optimization, military network in catastrophe environment

Sumário

1	Introdução	1
1.1	Objetivos	3
1.2	Estrutura da dissertação	3
2	Fundamentação Teórica	4
2.1	Pesquisa Operacional e a Programação Linear	4
2.2	Métodos de Otimização Discretos	7
2.2.1	Exatos	7
2.2.2	Aproximados	8
2.2.3	Heurísticos	8
2.2.4	Meta-heurísticos	9
2.3	Otimização Multiobjetivo	10
2.3.1	Visão Geral	10
2.3.2	Definições	11
2.3.3	Espaço de Projeto e Espaço de Critérios	13
2.3.4	Ótimo de Pareto	17
2.3.5	Condições Necessárias e Suficientes	19
2.3.6	Soluções de Consenso ou de Compromisso	19
2.4	Modelos de Predição de Sinal	20
2.4.1	O canal de rádio difusão	21
2.4.2	Planejamento da rede de RF - <i>Link Budget</i>	22
2.4.3	Classificação dos Modelos	23
2.5	Sistema de telefonia 4G/LTE	24
2.6	Considerações Parciais	28
3	Trabalhos Relacionados	29
3.1	Análise dos Trabalhos Relacionados	29
3.2	Discussão dos Trabalhos Relacionados	31
3.3	Considerações Parciais	31

4	Soluções otimizadas em redes militarizadas 4G/LTE	33
4.1	Sistema de Apoio à Decisão do CCOp Mv	33
4.2	Modelo do Sistema	35
4.3	Definição do Problema	37
4.4	Soluções Otimizadas	41
4.4.1	E-ALLOCATOR	41
4.4.2	M-ALLOCATOR	41
4.5	Considerações Parciais	44
5	Resultados	45
5.1	Cenários Modelados	45
5.2	Avaliação do M-ALLOCATOR	51
5.3	Avaliação de desempenho das soluções propostas	52
6	Conclusões	57
6.1	Principais Contribuições	58
6.2	Trabalhos Futuros	59
	Referências	60

Lista de Figuras

2.1	Arcabouço da Pesquisa Operacional.	5
2.2	Representação gráfica de uma otimização de único objetivo no espaço de projeto.	14
2.3	Representação gráfica de uma OMO com dois objetivos no espaço de projeto.	15
2.4	Representação gráfica de uma OMO com dois objetivos no espaço de critérios.	16
2.5	Transmissão do sinal de RF.	21
2.6	Arquitetura de um sistema 4G/LTE com destaque em verde para a camada em estudo.	26
4.1	Cenário de funcionamento do Sistema de Apoio à Decisão do CCOp Mv.	34
4.2	Etapa de Pré-processamento do SAD do CCOp Mv.	35
4.3	Etapa de Otimização do SAD do CCOp Mv.	35
5.1	Área da tragédia e de atuação das equipes de resgate.	46
5.2	Locais para implantação das BTSs.	47
5.3	Posição dos clientes do sistema ou UEs.	48
5.4	Matrizes de Adjacências entre as posições de BTSs M_{ij} e os UEs em N_{ij} para cada potência de transmissão p	49
5.5	Impacto de desempenho com a variação dos métodos de seleção.	51
5.6	Impacto de desempenho com a variação dos métodos de reprodução.	52
5.7	Impacto de desempenho com a variação dos métodos de mutação.	52
5.8	Número de BTSs (veículos do CCOp Mv) implantados.	53
5.9	Energia despendida com a Potência de Transmissão Total.	54
5.10	Grau de Sobreposição representando a interferência da sobreposição dos sinais das BTSs implantadas sobre os setores de UEs N_{ij}	54
5.11	Desvio Percentual Relativo (DPR) do ótimo de Pareto obtido pela solução E-ALLOCATOR.	55

5.12	Área Coberta expressa pela soma das áreas dos setores cobertos por pelo menos uma BTS.	55
5.13	Impacto do consenso de cobertura e das dimensões dos cenários sobre o tempo de processamento.	56

Lista de Tabelas

3.1	Comparação com os trabalhos relacionados.	31
4.1	Notação utilizada nesta obra.	36
4.2	Hyperparâmetros da solução M-ALLOCATOR ajustados.	44
5.1	Dimensões dos cenários propostos.	47
5.2	Parâmetros utilizados nos cenários modelados.	50

Lista de Abreviaturas e Siglas

3GPP *3rd Generation Partnership Project.*

4G/LTE 4ª Geração do Sistema de Telefonia Móvel também designada por Padrão de Longa Duração, do inglês *Long Term Evolution.*

5G 5ª Geração do Sistema de Telefonia Móvel.

AG Algoritmo Genético.

ATM *Asynchronous Transfer Mode.*

BB *Branch and Bound.*

BTS *Base Transceiver Station.*

CCOp Mv Centro de Coordenação de Operações Móveis.

DPR Desvio Percentual Relativo.

E-UTRAN *Evolved UMTS Terrestrial Radio Access Network.*

EPC *Evolved Packet Core.*

FSP Força do Sinal Prevista.

HDD *Hard Disk Drive.*

HF *High Frequency.*

HSS *Home Subscriber Server.*

IP *Internet Protocol.*

LOS *Line Of Sight.*

MCLP *Maximal Covering Location Problem.*

MIMO *Multiple Input – Multiple Output.*

MME *Mobility Management Entity.*

OFDMA *Orthogonal Frequency Division Multiplexing / Multiple Access.*

OMO *Otimização Multiobjetivo.*

P-GW *Packet Data Network Gateway.*

PL *Programação Linear.*

PLI *Programação Linear Inteira.*

PLIM *Programação Linear Inteira Mista.*

PO *Pesquisa Operacional.*

RAM *Random Access Memory.*

RF *Rádio Frequência.*

RMa *Rural Macro-Cell.*

RSRP *Reference Signal Received Power.*

RSSI *Received Signal Strength Indication.*

S-GW *Serving Gateway.*

SAD *Sistema de Apoio à Decisão.*

SCP *Set Covering Problem.*

SNR *Signal to Noise Ratio.*

SRDT *Sistema de Rádio Digital Troncalizado.*

TIC *Tecnologia da Informação e Comunicações.*

TR *Technical Report.*

UE *User Equipment.*

UHF *Ultra High Frequency.*

VHF *Very High Frequency.*

VM *Virtual Machine.*

Capítulo 1

Introdução

O posicionamento e a configuração das Estações Transceptoras Base, do inglês *Base Transceiver Station* (BTS), não são apenas cruciais para o desempenho das redes rádio celulares, mas também são uma das etapas que compõem o complexo processo de planejamento desses sistemas de comunicação. De acordo com [1], podemos resumir o planejamento de uma BTS em três etapas principais: (i) prever a área de cobertura definida por modelos empíricos de propagação; (ii) descrever analiticamente o tráfego demandado pelo serviço prestado; e (iii) determinar seu posicionamento e suas configurações. A previsão da área de cobertura determina o raio de acesso da BTS em que os usuários podem ser atendidos, fornecendo potência de sinal esperada por quilômetro quadrado de acordo com modelos de propagação empíricos já bem estabelecidos da literatura e indústria [2]. Já a descrição analítica do tráfego requerido por um serviço contempla a carga de trabalho a ser suportada pelo sistema de comunicação sem fio, definindo os requisitos de métrica de desempenho a serem atendidos, tais como capacidade mínima entregue e latência máxima com terminais de comunicação. Por fim, a localização da BTS define o posicionamento geográfico considerando a instalação de todos os elementos necessários, tais como mastros, antenas e as próprias estações rádio-base. Cada etapa traz uma nova complexidade para planejar uma BTS, assim, os Sistemas de Apoio à Decisão (SAD) foram propostos como forma de automatizar o processamento das informações necessárias para o melhor posicionamento e descoberta da melhor configuração para esses equipamentos [3, 4, 5, 6, 7, 8, 9, 10, 11].

Em relação ao SAD, a idealização do projeto Centro de Coordenação de Operações Móveis (CCOp Mv) visa a criação de um centro de comando e controle para apoiar o comando operacional do Exército Brasileiro. Diferentemente das tradicionais redes de acesso rádio baseadas em estações de base fixas, as BTSs do CCOp Mv são veículos militares equipados com diferentes tipos de enlaces de comunicação. A 4ª Geração do Sistema de Telefonia Móvel também designada por Padrão de Longa Duração, do inglês *Long Term Evolution* (4G/LTE), prevalece entre as tecnologias de comunicação disponí-

veis. A mobilidade na infraestrutura permite que a rede de acesso via rádio se adapte dinamicamente para melhorar a eficiência espectral e reduzir o consumo de energia de transmissão. Embora não seja fixo, definir a melhor posição geográfica desses veículos em campo para permitir cobertura adequada para operações militares que requerem comunicação por meio da 4G/LTE não é uma tarefa trivial. Esta tarefa faz parte do planejamento do melhor posicionamento e configuração das BTSs e é tratada como uma derivação do Problema de Localização de Cobertura Máxima, do inglês *Maximal Covering Location Problem* (MCLP) [12]. O MCLP é um problema NP-completo, cujo objetivo é criar uma área de cobertura para atender o maior número de pontos de demanda apresentados.

Diferentes SADs foram propostos para lidar com o MCLP. Por um lado, soluções propostas na literatura sugerem melhorias para lidar com MCLP geralmente sem considerar particularidades de aplicações com domínios específicos [13, 4, 5, 6]. Por outro lado, existem algumas abordagens que exploram aplicações MCLP com domínios específicos, como a implantação de garagens de veículos [8], alocação de antenas [3] ou mesmo veículos de comunicação [7] aplicados em operações de resgate. Em [3, 4, 5, 6, 7, 8, 11], as soluções visam maximizar a cobertura considerando exclusivamente o problema de posicionamento de antenas que impactam o desempenho da rede sem considerar outras características. Em contrapartida, os trabalhos de [14] e [15] exploram apenas a otimização da área de cobertura das redes já instaladas ajustando a potência de transmissão de suas BTSs sem determinar seus melhores posicionamentos.

Como sugerido em [16] e [17], problemas reais geralmente envolvem múltiplos objetivos. Guiados por esta premissa e visando determinar o posicionamento e a configuração das BTSs transportadas pelos veículos do CCOp Mv de forma mais realista, *i.e.*, envolvendo todas as variáveis possíveis que impactam o problema, é que este trabalho buscou investigar as soluções de otimização a partir de dois objetivos conflitantes. Eles são *(i)* a maximização da cobertura e *(ii)* a minimização da interferência entre os sinais das *Base Transceiver Stations*. Do exposto, fica evidente que o nosso problema consiste em determinar o número de veículos a serem utilizados, suas posições e as potências de transmissão configuradas em cada BTS que maximizem a área de cobertura e minimizem a interferência entre as células de comunicação criadas. Estas tarefas serão recorrentes para cada operação militar que deseje fazer uso dos serviços do CCOp Mv e intimamente ligadas às características do relevo e geografia do ambiente de emprego deste sistema de comunicação militar.

1.1 Objetivos

Este trabalho visa propor, desenvolver e avaliar soluções de otimização que resolvam o problema de localização e configuração das BTSs do CCOp Mv. Para tanto, foram analisados os mecanismos de otimização estudados em Pesquisa Operacional (PO), as técnicas de modelagem de problemas reais, a tecnologia de comunicação 4G/LTE, os mecanismos de predição de propagação de ondas eletromagnéticas e a metodologia de avaliação empregada para a análise comparativa das soluções [18].

Dadas as características do *Maximal Covering Location Problem* e pela proposta deste trabalho ser uma extensão deste problema, será apresentada uma modelagem analítica fundamentada em Programação Linear Inteira Mista. Esta modelagem se adequa à descrição dos cenários de avaliação e reflete matematicamente a influência das variáveis que coordenam o problema em estudo. A partir desta modelagem matemática é que foram fundamentadas as duas soluções de otimização propostas para a resolução do problema de localização e configuração das BTSs com máxima cobertura e mínima interferência, que são: (i) E-ALLOCATOR – Exact ALLOCATiOn seRvice; e (ii) M-ALLOCATOR – Metaheuristic ALLOCATiOn seRvice.

1.2 Estrutura da dissertação

O restante desta dissertação está estruturado da seguinte forma. O Capítulo 2 discute os principais conceitos relacionados ao tema desta pesquisa e que a fundamentam. O Capítulo 3 apresenta trabalhos relacionados com foco na implantação e configuração da BTS. Enquanto o Capítulo 4 apresenta a estratégia adotada para modelar o E-ALLOCATOR e o M-ALLOCATOR. O Capítulo 5 apresenta os resultados para validar as soluções propostas. Por fim, o Capítulo 6 apresenta as conclusões e trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Neste capítulo, é apresentada a fundamentação teórica com a finalidade de fornecer subsídios à compreensão dos próximos capítulos. Inicialmente, é apresentado um embasamento teórico sobre Pesquisa Operacional, a técnica de Programação Linear e suas aplicações. Subsequentemente, é realizado um estudo dos métodos de otimização discretos e das técnicas e conceitos atinentes à otimização multiobjetivo. Além disso, são apresentados e discutidos os conceitos de modelos de predição de sinal do espectro de Rádio Frequência. Finalmente, são apresentados e discutidos os conceitos da tecnologia de 4^a geração de telefonia móvel para o entendimento da solução proposta nesta Dissertação.

2.1 Pesquisa Operacional e a Programação Linear

Segundo definição da Sociedade Brasileira de Pesquisa Operacional (SoBraPO) [19], Pesquisa Operacional (PO) é a área de conhecimento que estuda, desenvolve e aplica métodos analíticos avançados para auxiliar na tomada de melhores decisões nas mais diversas áreas de atuação humana. Neste contexto, conforme visualizado na Figura 2.1 é através do uso de técnicas de modelagem matemática e eficientes algoritmos computacionais, a PO pode auxiliar o decisor na análise dos mais variados aspectos e situações de um problema complexo, permitindo a tomada de decisões efetivas e a construção de sistemas mais eficientes e produtivos. Ainda segundo a SoBraPO [19], o aumento da capacidade de processamento computacional e a possibilidade de lidar com problemas cada vez maiores, tem impulsionado o desenvolvimento de novos métodos analíticos que estão em constante evolução e propiciam uma vasta gama de aplicações.

Métodos envolvendo programação matemática (entre elas a Programação Linear), simulação, teoria dos jogos, teoria das filas, análise de redes, teoria de decisão, aprendizado de máquina e ciência dos dados são reconhecidos por sua poderosa capacidade de apresentar soluções efetivas para problemas aplicados.

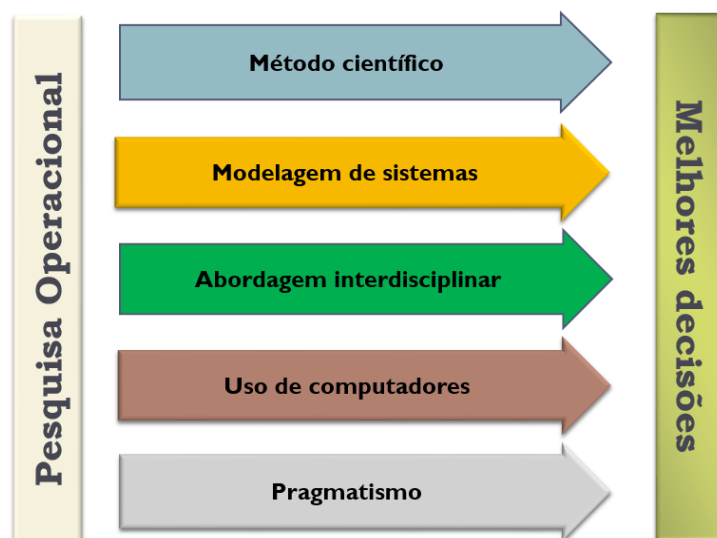


Figura 2.1: Arcabouço da Pesquisa Operacional.
(Fonte: SoBraPO [19])

De acordo com Barbosa [20], a PO é uma ciência aplicada que oferece mecanismos para:

- resolver problemas reais;
- tomar decisões com base em dados e correlações quantitativos;
- criar, planejar e operar sistemas por meio de tecnologias e métodos de diversas áreas de conhecimento (PO é interdisciplinar);
- diminuir os custos e maximizar o lucro; e
- encontrar a solução ótima.

Entre as aplicações da PO, Lachtermacher [21] relaciona uma série de situações/problemas em que ela pode auxiliar no processo de tomada de decisão:

- otimização de recursos;
- localização;
- roteirização;
- carteiras de investimento;
- alocação de pessoas;
- previsão de planejamento;
- entre outros.

Ainda de acordo com Lachtermacher [21], entre as diversas técnicas estudadas pelo ramo de Pesquisa Operacional a técnica que se destaca para a resolução dos problemas associados à alocação de recursos é a técnica de Programação Linear (PL).

Segundo Taha [22] a PL foi desenvolvida conceitualmente após a Segunda Guerra Mundial, pelo soviético Kolmogorov, com o objetivo de resolver problemas de logística militares. Entretanto, o grande marco dos estudos de PL ocorreu em 1947, com o desenvolvimento do método de resolução de problemas de PL denominado “Método Simplex”. Ele foi proposto pelo matemático Dantzig. Mais recentemente em 1984, Karmakar desenvolveu um algoritmo que se tem mostrado superior ao simplex na resolução de problemas de PL extremamente grandes. Contudo, ainda segundo Taha [22], o Método Simplex continua sendo o mais utilizado nos dias de hoje e é a base de *solvers* de planilhas eletrônicas. Andrade [23] explica que o Método Simplex percorre os vértices da região viável até encontrar uma solução que não possua soluções vizinhas melhores que ela, tendo assim a solução ótima. Em alguns casos a solução ótima não pode ser encontrada, devido à falta de solução viável para o problema ou então quando uma ou mais variáveis tendem ao infinito, fazendo com que as restrições continuem sendo satisfeitas, o que fornece um valor sem limites para a função objetivo.

Segundo Barbosa [20], PL é uma técnica de otimização aplicada em sistemas de equações e inequações lineares representativos de modelos matemáticos que descrevem o problema sob análise. Estes modelos são constituídos de variáveis de decisão, funções objetivo e equações que modelam as restrições, estes dois últimos expressos por equações ou inequações lineares. Consiste, portanto, em uma técnica de otimização fundamentada no contexto matemático de equações ou inequações lineares que modelam o problema em estudo a ter sua solução ótima descoberta.

A formulação geral para um problema de Programação Linear e dado pela Equação 2.1:

$$\text{Encontre:} \quad x = [x_1, x_2, x_3, \dots, x_m] \quad (2.1)$$

$$\text{Para minimizar:} \quad F(x) = a_1 \cdot x_1 + a_2 \cdot x_2 + a_3 \cdot x_3 + \dots + a_m \cdot x_m$$

$$\text{Sujeito a:} \quad r_d(x) \leq 0; \quad \forall d = \{1, 2, 3, \dots, D\}$$

$$h_j(x) = 0; \quad \forall l = \{1, 2, 3, \dots, J\}$$

Onde m é o número de variáveis de decisão que foram consideradas na modelagem do problema, D o número de restrições de desigualdade e J o número de restrições de igualdade. $x \in E^m$ é um vetor de variáveis de decisão x_i , $a_i \in \mathbb{R}$ são os pesos atribuídos às variáveis de decisão e $F(x)$ é a função objetivo $F(x) \in \mathbb{R}^1$. O espaço de soluções viáveis é definido como o conjunto de vetores de x que atendem às restrições do problema (r_d e

h_j) sendo, portanto, definido como $X = \{x | r_d(x) \leq 0, \forall d = 1, 2, \dots, D; e h_j(x) = 0, \forall j = 1, 2, \dots, J\}$.

Os problemas de otimização fundamentados em PL são divididos em três categorias: (i) aqueles cujas variáveis assumem valores reais (ou contínuos, $x \in \mathbb{R}$), (ii) aqueles cujas variáveis assumem valores discretos (ou inteiros, $x \in \mathbb{Z}$) e (iii) aqueles em que há variáveis inteiras e contínuas (mistos, $x_i \in \mathbb{Z}$ e $x_k \in \mathbb{R}$), classificados, respectivamente, como problemas de Otimização Contínua, Otimização Combinatória ou Discreta, e Otimização Mista. Da mesma forma e na mesma ordem as técnicas que solucionam estes problemas são a Programação Linear (PL), a Programação Linear Inteira (PLI) e a Programação Linear Inteira Mista (PLIM). Focaremos nesta pesquisa na classe de problemas de Otimização Mista, tratadas e resolvidas pelas técnicas de PLIM.

Arenales *et al.* [24] afirmam que problemas de programação inteira e mista são resolvidos:

- por métodos exatos, que fornecem uma solução ótima; ou
- por algoritmos aproximados, que garantem a distância máxima entre o valor da solução subótima encontrada e o valor ótimo; ou
- por métodos heurísticos ou meta-heurísticos, que, em geral, fornecem uma solução subótima, sem conhecimento da qualidade desta em relação a uma solução ótima.

Para esta pesquisa pretende-se realizar a modelagem do problema de alocação das eNodeBs do sistema de telefonia 4G/LTE do CCOp Mv baseadas na técnica de modelagem PLIM e nos mecanismos de otimização discretos apresentados na seção seguinte.

2.2 Métodos de Otimização Discretos

Os métodos de otimização são os algoritmos ou as implementações computacionais que resolvem os problemas previamente modelados. Eles podem ser divididos em métodos exatos, aproximados, heurísticos e meta-heurísticos conforme explorados a seguir.

2.2.1 Exatos

Uma forma de obter uma solução ótima para um problema é utilizar um processo exaustivo, enumerando todas as soluções viáveis de acordo com as restrições do modelo de modo que o valor de todas as soluções factíveis é calculado, e escolhe-se a de maior valor (em problemas de maximização) ou a de menor valor (em problemas de minimização).

Explorar todas as soluções viáveis pode ser muito custoso ou até inviável a depender do tamanho do problema a ser estudado. É por isso que muitas pesquisas para descobrir

mecanismos de redução deste custo foram empreendidas e de acordo com Barbosa *et al.* [20] uma forma de reduzir o espaço de busca consiste em usar informação do problema de programação linear para executar um procedimento denominado enumeração implícita, em que subconjuntos de soluções são implicitamente considerados e descartados, pois não contêm uma solução ótima, ou contêm soluções ótimas distintas, mas de mesmo valor. Estes subconjuntos são obtidos pela estratégia dividir para conquistar, que separa o problema original em problemas menores que requerem menor esforço computacional para serem resolvidos. Esta estratégia é usada nos métodos *branch-and-bound* (B&B), plano de corte e *branch-and-cut* (B&C). Muito provavelmente é devido a estas estratégias de redução da complexidade computacional destes mecanismos que Arenales *et al.* [24] afirmam que os métodos exatos mais empregados para resolver problemas genéricos de PLIM são baseados nos enfoques B&B e planos de corte e na combinação destes, o método B&C.

2.2.2 Aproximados

Algoritmos de aproximação são mecanismos que geram soluções com diferença pré-determinada entre os valores de uma solução subótima e de uma solução ótima. A ideia por trás desta classe de algoritmos é que para reduzir a complexidade da busca pelas soluções, abre-se mão da otimalidade destas soluções, mas garante-se o quão distante estas soluções subótimas estarão da solução ótima.

Entre os algoritmos desta classe cita-se o algoritmo *a priori*, que estabelece a distância entre o valor de todas as instâncias factíveis e o valor ótimo. Existe também o algoritmo aproximado *a fortiori* em que a distância é dada pelo valor da solução de cada instância. Neste caso, o valor da solução subótima está mais próximo do valor ótimo do que o valor fornecido por um algoritmo do tipo *a priori*.

Ressalta-se dois aspectos em um algoritmo de aproximação: (i) a existência de um algoritmo em tempo polinomial para problemas NP-difíceis e (ii) no caso de um algoritmo de aproximação *a priori*, o requisito de produzir uma solução subótima para todas as instâncias.

2.2.3 Heurísticos

O termo Heurística deriva da palavra grega *Heuriskein* que significa descobrir. Esse termo é usado para descrever um método que, baseado na experiência ou julgamento, parece conduzir a uma boa solução de um problema, mas que não garante produzir uma solução ótima. Também podemos considerar esse termo como associado a um conhecimento circunstancial, não verificável, nem matematicamente verificável. É comum encontrarmos

a expressão “heurística gulosa”, ou “*Greedy Heuristic*”. O método guloso é um exemplo de heurística. Ele fundamenta sua solução do problema de otimização por meio da busca das variáveis que mais reduzem o custo total de forma mais imediata. Este princípio é executado em várias iterações até que todos os elementos da solução tenham sido calculados. A heurística gulosa apresenta a vantagem de ser rápida e, em alguns casos, produzir soluções eficientes.

Em resposta à dificuldade computacional para se obter soluções ótimas para muitos dos problemas de otimização, foram elaborados algoritmos heurísticos que buscam tirar proveito de características e informações do próprio problema. Informalmente, um algoritmo heurístico, ou simplesmente heurística, é um algoritmo que objetiva encontrar soluções viáveis “boas”, ou seja, com valor objetivo próximo ao de uma solução ótima, mas sem oferecer um grau predeterminado de certeza quanto à qualidade das soluções encontradas em relação às soluções ótimas; e em tempo computacional inferior a um método exato. Os métodos heurísticos procuram um compromisso entre o desempenho na obtenção de uma solução e a qualidade da solução. A qualidade da solução pode ser medida por meio da aplicação de uma métrica que compare o valor obtido e o valor da solução ótima. Devido à complexidade dos problemas de otimização combinatória e por serem muito sensíveis ao tamanho do problema a ser analisado, trabalha-se com métodos heurísticos para alcançar resultados aceitáveis num tempo computacional viável.

São mecanismos que tem prova de convergência, ou seja, é possível garantir que caminhem em direção à solução ótima. Porém, não garantem a descoberta da solução ótima. Fundamentam-se em procedimentos que tem um enfoque intuitivo no qual a estrutura do problema possa ser interpretada e explorada de forma inteligente para obtenção de uma solução razoável. Cabe destacar que este enfoque intuitivo é a exploração das características associadas a cada problema. Por isso, pode-se dizer que os métodos heurísticos são específicos e estão intimamente relacionados à natureza do problema em estudo.

As principais técnicas heurísticas são: (i) construtivas; (ii) de Relaxação; e (iii) de Busca Local.

2.2.4 Meta-heurísticos

Já o termo "meta-heurística" deriva da composição de duas palavras gregas: "heurística", já explicada anteriormente, e o prefixo "meta", que significa “após”, indicando um nível superior de descoberta. Segundo Sörensen e Glover [25] uma metaheurística é uma estrutura algorítmica de alto nível, independente de problemas, que fornece um conjunto de diretrizes ou estratégias para desenvolver algoritmos de otimização heurísticos. Ou seja, assim como nos algoritmos heurísticos, não garantem a obtenção da solução ótima, têm prova de convergência e se fundamentam no compromisso entre desempenho e qualidade

da solução subótima fornecida. A principal diferença entre os métodos heurísticos e meta-heurísticos é que nestes últimos são exploradas diretrizes gerais a todos os problemas de otimização e não como nos anteriores, as características específicas dos problemas. Os métodos meta-heurísticos são formados por um conjunto de técnicas genéricas que definem estratégias globais para solucionar praticamente qualquer problema de otimização, independente do seu tipo ou natureza. Por isso eles podem ser aplicados a um conjunto amplo de diferentes problemas, necessitando de modificações relativamente pequenas para torná-los adaptáveis a um problema específico.

Entre suas técnicas cita-se: (i) *simulated annealing*; (ii) algoritmo genético; (iii) algoritmo memético; (iv) busca tabu; (v) GRASP; (vi) algoritmos probabilísticos.

2.3 Otimização Multiobjetivo

Boa parte da teoria sobre Otimização Multiobjetivo (OMO) diverge dos paradigmas de otimizações de único objetivo. Assim, esta seção aborda os conceitos básicos que são necessários para a análise e desenvolvimento de métodos de solução de problemas de Otimização Multiobjetivo como os propostos neste trabalho. Inicialmente, uma visão geral sobre OMO será apresentada. Em seguida, ideias gerais sobre preferências e os tipos de métodos são explicados. Os dois espaços vetoriais que são usados para representar problemas de OMO são ilustrados. A otimalidade de Pareto é discutida em detalhes, e as variações deste conceito são definidos. Por fim, a programação de compromisso é apresentada como um conceito alternativo de otimização.

2.3.1 Visão Geral

O processo de otimizar simultaneamente um conjunto de funções objetivo recebe o nome de Otimização Multiobjetivo (OMO) e o problema geral é formulado como a seguir:

$$\text{Encontre:} \quad x = [x_1, x_2, x_3, \dots, x_m] \quad (2.2)$$

$$\text{Para minimizar:} \quad F(x) = [F_1(x), F_2(x), F_3(x), \dots, F_n(x)]$$

$$\text{Sujeito a:} \quad \begin{aligned} r_d(x) &\leq 0; & \forall d = \{1, 2, 3, \dots, D\} \\ h_j(x) &= 0; & \forall l = \{1, 2, 3, \dots, J\} \end{aligned}$$

Onde m é o número de variáveis de decisão que foram consideradas na modelagem do problema, n o número de funções objetivo, D o número de restrições de desigualdade e J o número de restrições de igualdade. $x \in E^m$ é um vetor de variáveis de decisão x_i e $F(x) \in E^n$ é um vetor de funções objetivo $F_i(x) : E^m \rightarrow E^1$. O espaço de soluções viáveis

é definido como o conjunto de vetores de x que atendem às restrições do problema (r_d e h_j) sendo, portanto, definido como $X = \{x | r_d(x) \leq 0, \forall d = 1, 2, \dots, D; e h_j(x) = 0, \forall j = 1, 2, \dots, J\}$.

Em um problema de OMO não há uma única solução definida. A melhoria em um objetivo geralmente resulta em prejuízo para outros. Neste cenário, o conceito de solução predominante é o ótimo de Pareto, que define que um ponto é ótimo de Pareto se e somente se for impossível sair desse ponto e reduzir pelo menos uma função objetivo sem aumentar (ou seja, prejudicar) qualquer outra função. Este conceito determina no espaço de soluções viáveis um conjunto de soluções.

Encontrado um conjunto de soluções, surge a questão de qual solução será de fato implementada ou escolhida. O resultado de um problema de Otimização Multiobjetivo leva a um problema de decisão em que os tomadores de decisão deverão escolher entre o conjunto de alternativas aquela que se mostra mais interessante. Normalmente, existem infinitos pontos ótimos de Pareto para um problema, e estabelecer um ponto requer que o tomador de decisão articule preferências e defina suas prioridades e utilidades de alguma forma. De acordo com o momento que ocorre a articulação de preferências, ou seja, que o decisor escolhe a solução que mais o agrada entre o conjunto de soluções de Pareto é que se classificam os métodos de OMO em: (i) a priori, (ii) progressivo, ou (iii) a posteriori.

2.3.2 Definições

A Otimização Multiobjetivo originalmente surgiu de três áreas: (i) equilíbrio econômico e teorias de bem-estar, (ii) teoria dos jogos e (iii) matemática pura. Consequentemente, muitos termos e ideias fundamentais derivam desses campos e Yann Collette e Patrick Siarry (2004) [26] apresentam discussões aprofundadas sobre esses tópicos. A seguir serão descritos os principais termos que fundamentam as pesquisas em Otimização Multiobjetivo.

As **preferências** refletem as opiniões de um tomador de decisão sobre o conjunto de soluções no espaço de critérios, indicando qual ponto será a solução escolhida e a que será implementada. Como um dos objetivos da OMO é modelar matematicamente as preferências do decisor, é necessário incluir as preferências do decisor no processo de otimização. Assim, os métodos podem ser categorizados dependendo de como e principalmente quando o tomador de decisão incorpora suas preferências ao processo. Os três tipos são: (i) **a priori**, (ii) **a posteriori** e progressivos.

Nos métodos **a priori** o decisor deve indicar suas preferências em relação às funções objetivo ou suas intenções e prioridades antes de executar o algoritmo de otimização. Ele deve ponderar o grau de importância das funções objetivo antes que o processo de otimização seja executado e sejam elencados os pontos de solução no espaço de critérios. Nestes métodos a *trade-off* entre as funções objetivo é determinado e modelado antes da

execução do método de otimização. Desta forma o problema multiobjetivo é convertido em um problema de único objetivo e uma solução é gerada pelos mecanismos apresentados na Seção 2.2. Alterando a relação de *trade-off* entre as funções objetivo, uma nova solução pode ser gerada, até que o decisor esteja satisfeito (decide \Rightarrow otimiza).

Nos métodos **a posteriori** este processo se inverte e uma solução de um grupo de soluções matematicamente equivalentes é selecionada após a execução do algoritmo de otimização. Neles o processo inicia-se com a execução da otimização. Um conjunto de soluções viáveis é então encontrado e apresentado ao decisor. Somente nesta etapa é que o decisor é requisitado a apresentar suas preferências em um conjunto de potenciais pontos de solução. Não é necessária a modelagem de preferências do decisor, mas o processo de otimização é mais complexo e computacionalmente caro, porque várias soluções devem ser geradas até que o decisor tome sua decisão (otimiza \Rightarrow decide).

A articulação de preferências **progressiva** requer que o tomador de decisão forneça continuamente informações durante a execução de um algoritmo. Nele, consultas ao decisor durante a otimização orientam a busca na direção da solução do *trade-off* que existe entre as funções objetivo. Ele requer a atenção do decisor durante o processo de otimização (decide \Leftrightarrow otimiza). O uso dessa abordagem pode ser relativamente eficiente (em termos de esforço computacional), pois se esforça para produzir apenas um subconjunto do conjunto completo de soluções potenciais, regidas pelas preferências do usuário [27]. No entanto, embora essas abordagens reflitam com precisão as intenções do usuário, elas não podem funcionar de forma independente. O usuário deve atender ao algoritmo enquanto ele é executado. Conseqüentemente, tais métodos não são adequados para uso repetitivo e não são considerados neste estudo.

Uma **função de preferência** $P[F(x)]$ é uma função abstrata (de pontos no espaço de critérios) na mente do decisor, que incorpora suas preferências. Nos métodos que envolvem a articulação *a priori* de preferências, o significado físico de cada objetivo fornece entrada para a função de preferência que por sua vez é a entrada do processo de otimização. Já nos métodos progressivo, o decisor fornece a saída da função de preferência em forma de parâmetros, que são coeficientes que determinam os pesos de cada função objetivo. Esses pesos são definidos para refletir as preferências do tomador de decisão ou continuamente alterados para encontrar o Conjunto ótimo de Pareto. Alternativamente, o tomador de decisão pode fornecer saída na forma de metas ou uma ordenação dos objetivos. No entanto, uma vez que essas informações estejam integradas em uma formulação multiobjetivo, a solução final pode não ser aceitável. Por outro lado, com métodos que envolvem a articulação *a posteriori* de preferências, o decisor impõe preferências diretamente sobre um conjunto de potenciais pontos de solução (no espaço de projeto ou no espaço de critério). Dessa forma, a solução final reflete com maior precisão as preferências

do decisor.

No contexto da economia, a utilidade, que é modelada com uma **função de utilidade**, representa o grau de contentamento de um indivíduo ou grupo [26]. Esse uso de “utilidade” é um pouco diferente de seu significado usual como utilidade ou valor. No contexto de OMO, a utilidade representa a satisfação do tomador de decisão. De forma análoga à função de preferência, uma função de utilidade expressa a importância relativa de cada objetivo em termos de sua capacidade de modelar as preferências do decisor, porém na forma de equações matemáticas $U : E^n \rightarrow E^1$.

Uma das classificações predominantes de abordagens multiobjetivos são os métodos de escalarização e métodos de otimização vetorial. Nos **métodos de escalarização**, dado um vetor de funções objetivo, os componentes desse vetor são combinados para formar uma única função objetivo, de forma similar a uma otimização de objetivo único. Então, pode-se usar os métodos de otimização de objetivo único vistos na Seção 2.2 para otimizar a função escalar resultante. Já os métodos de **otimização vetorial** buscam soluções para cada função objetivo de maneira independente.

A maioria das abordagens à OMO envolve uma reformulação do problema em 2.2. Diferentes algoritmos simplesmente respondem de maneiras diferentes à questão de como incorporar múltiplas funções objetivo. No entanto, não importa como se priorize ou combine as múltiplas funções objetivo, em última análise, geralmente depende de um único objetivo, rotina de otimização restrita para resolver o problema OMO. Essa abordagem de otimização de objetivo único é chamada de **mecanismo de otimização**. Diferentes mecanismos de otimização não são avaliados, apenas os vários métodos para lidar com várias funções de objetivo são.

2.3.3 Espaço de Projeto e Espaço de Critérios

Do ponto de vista clássico, otimizar uma única função envolve simplesmente determinar um conjunto de pontos estacionários, identificar um máximo ou mínimo local e, possivelmente, encontrar o ótimo global. Em contraste, o processo de determinar uma solução para um problema OMO é um pouco mais complexo e menos definido do que para um problema de objetivo único. No processo de OMO não é evidente o entendimento do mínimo ou máximo de múltiplas funções. Isto ocorre pois as funções objetivo podem ter características opostas e conflitantes *i.e.*, o que diminui o valor de uma das funções pode aumentar o valor de outra. Para entender melhor a dificuldade em definir um ótimo para um problema multiobjetivo, pode ser ilustrativo considerar um problema gráfico simples.

Para começar, considere um problema básico de minimização de objetivo único formulado pela Equação 2.3 e ilustrado na Figura 2.2:

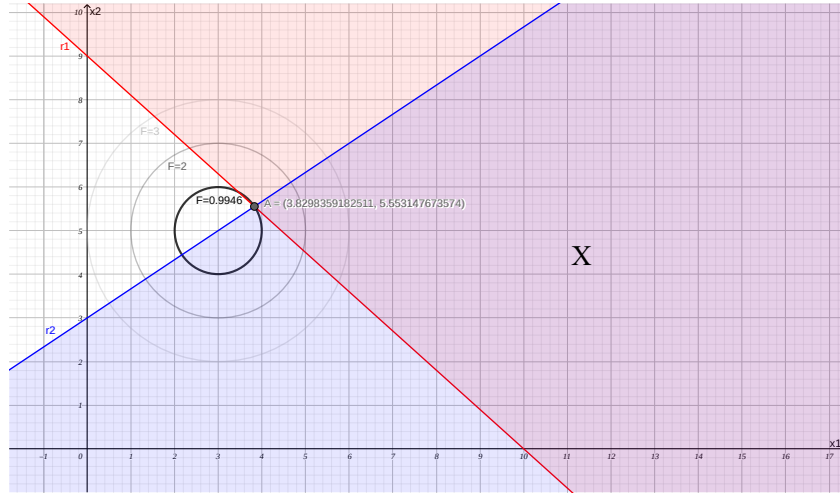


Figura 2.2: Representação gráfica de uma otimização de único objetivo no espaço de projeto.

(Fonte: o autor)

Encontre: $x = [x_1, x_2]$ (2.3)

Para minimizar: $F(x) = (x_1 - 3)^2 + (x_2 - 5)^2$
 Sujeito a: $r_1 = 90 - 10x_2 - 9x_1 \geq 0$
 $r_2 = 3x_2 - 2x_1 - 9 \leq 0$

A Figura 2.2 mostra o problema de otimização no espaço de projeto. Neste exemplo as restrições são expressas pelas retas r_1 e r_2 que são inequações que delimitam o espaço de soluções viáveis. A intersecção entre a região acima da reta r_1 , área vermelha, e a região abaixo da reta r_2 , área azul, forma o espaço de soluções viáveis no espaço de projeto, área roxa. Na Figura 2.2 também estão presentes os contornos da função objetivo em termos das variáveis de projeto ou decisão x_1 e x_2 , que neste exemplo são círculos com centro no ponto (3,5). Observe que o problema tem um mínimo distinto no Ponto A (3.8298359182511, 5.553147673574) com um valor de função objetivo de 0,9946.

Um problema OMO pode ser representado em termos semelhantes, como mostrado na Figura 2.3, para o problema de dois objetivos modelado pela Equação 2.4:

Encontre: $x = [x_1, x_2]$ (2.4)

Para minimizar: $F_1(x) = (x_1 - 3)^2 + (x_2 - 5)^2$
 $F_2(x) = (x_1 - 5)^2 + (x_2 - 7)^2$

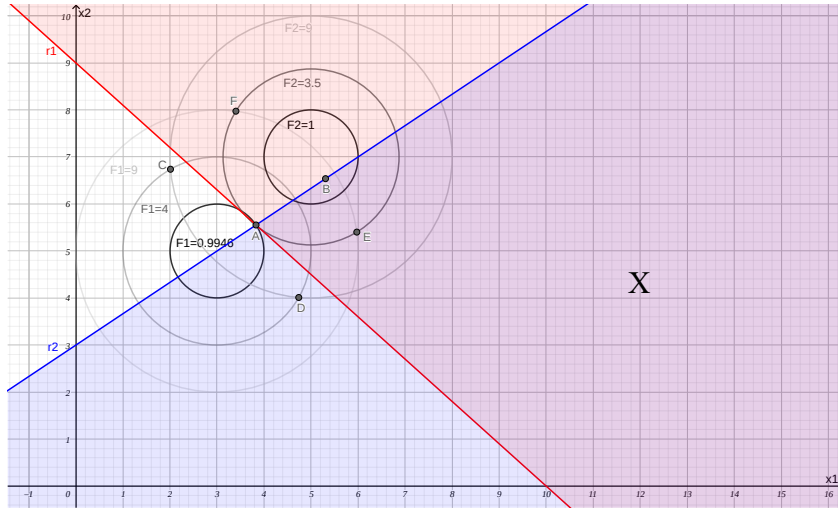


Figura 2.3: Representação gráfica de uma OMO com dois objetivos no espaço de projeto.
(Fonte: o autor)

Sujeito a:

$$r_1 = 90 - 10x_2 - 9x_1 \geq 0$$

$$r_2 = 3x_2 - 2x_1 - 9 \leq 0$$

Na Figura 2.3, o Ponto A representa o mínimo para a função objetivo F1 e o Ponto B (5.3077, 6.5385) representa o mínimo para a função objetivo F2 com um valor de 0,3077. No entanto, a intenção é minimizar F1 e F2 simultaneamente. Destes exemplos básicos fica claro a diferença de complexidade entre a identificação de um ponto ótimo para um problema de otimização mono-objetivo e de um problema de Otimização Multiobjetivo. Cabe destacar que as funções objetivo dos exemplos aqui apresentados são muito simples e daí ressalta-se a dificuldade de definir uma solução para OMO.

A visualização das possíveis soluções de uma Otimização Multiobjetivo é melhor representada no espaço de critérios. Diferentemente do espaço de projetos onde as funções objetivo são apresentadas em função das variáveis de decisão (no exemplo x_1 e x_2) das quais dependem, nesta representação gráfica fica mais evidente o *trade-off* entre as funções objetivo, dado que elas são visualizadas em função dos valores objetivo de cada uma das funções objetivo (no exemplo $F_1(x)$ e $F_2(x)$). Portanto, um problema OMO também pode ser representado no espaço de critérios Z , onde os eixos representam as diferentes funções objetivo, conforme mostrado na Figura 2.4.

Na Figura 2.4 c_1 representa r_1 e c_2 representa r_2 . Em geral, uma curva no espaço de projeto, na forma $r_j(x) = 0$, é mapeada em uma curva no espaço critério, c_j , como segue:

$$c_j = \{F(x) | r_j(x) = 0\} \quad (2.5)$$




Figura 2.4: Representação gráfica de uma OMO com dois objetivos no espaço de critérios.
(Fonte: o autor)

Embora c_1 e c_2 representem respectivamente o mapeamento de r_1 e r_2 no espaço de critérios, eles não representam necessariamente os limites do espaço de critério viável (também chamado de conjunto atingível), que é definido como $Z = \{F(x) | x \in X\}$. A porção de desigualdade de uma restrição não se traduz diretamente entre o espaço de projeto viável e o espaço de critério viável. Isso é visto na Figura 2.4, onde todas as partes das curvas c_1 e c_2 não formam necessariamente limites do espaço de critério viável. Isso pode ser visto no mapeamento da Figura 2.3 para a Figura 2.4, em que o Ponto F da Figura 2.3 é inviável, mas na Figura 2.4, ele ocupa a mesma posição (9,3.5) que o ponto E que é viável na Figura 2.3 e ficam entre as duas curvas c_1 e c_2 . Cada vetor de variáveis de decisão $x \in X$ do espaço de projeto pode ser mapeado em um ponto com as coordenadas $F_1(x), F_2(x), \dots, F_n(x)$ no espaço de critérios. O espaço de critérios Z é, portanto, a imagem imposta pelas funções objetivo do espaço de projeto X . Embora Z seja indicado na Figura 2.4, que descreve um problema relativamente simples, geralmente um mapeamento explícito do espaço de projeto viável para o espaço de critério viável não está prontamente disponível.

Embora os termos espaço de critério viável e conjunto atingível sejam usados na literatura para descrever Z , há uma distinção sutil entre as ideias de viabilidade e atingibilidade. Para que uma solução seja considerada viável significa que ela não viola nenhuma das restrições do problema. Já para que ela seja considerada atingível é necessário que haja o mapeamento dela no espaço de critérios para o espaço de projeto. Cada ponto no espaço de projeto x pode ser mapeado para um ponto correspondente no espaço de critérios pela aplicação do conjunto de funções objetivo $F(x) = [F_1(x), F_2(x), \dots, F_n(x)]$. Entretanto, o inverso pode não ser verdadeiro a exemplo dos pontos C-D e E-F vistos nas Figuras 2.3 e 2.4. Este exemplo deixa claro que um ponto no espaço de critérios não corresponde

necessariamente a um único ponto $x \in X$ do espaço de projeto. A consequência disso é que apenas certos pontos no espaço de critério são atingíveis. Neste trabalho o termo Z é empregado apenas para os pontos no espaço de critérios que são viáveis e atingíveis.

Atenção especial deve ser dada ao mapeamento entre o espaço de critérios e o espaço de projeto, pois para um dado ponto no espaço de critério viável, pode haver pontos correspondentes viáveis ou inviáveis no espaço de projeto. Por exemplo, os pontos E e F na Figura 2.3 resultam em um valor para F_1 de 9 e um valor para F_2 de 3,5. Conseqüentemente, embora o Ponto E seja viável e o ponto F seja inviável, ambos os pontos correspondem ao Ponto EF na Figura 2.4.

Os produtos de um problema de otimização, em termos de aplicação prática, geralmente são os valores ótimos das variáveis de decisão, não os valores da função objetivo. Conseqüentemente, um engenheiro ou tomador de decisão normalmente está interessado em resultados em termos de espaço de projeto. No entanto, as decisões geralmente são tomadas em termos do espaço de critérios, com base nos valores de diferentes objetivos. Os diagramas do espaço de critérios são particularmente úteis quando vários objetivos são combinados em um único objetivo composto. O objetivo composto pode então ser representado graficamente em função dos objetivos iniciais. Estudar o espaço de critério é mais benéfico quando há um número relativamente pequeno de funções objetivo, independentemente do número de variáveis de projeto. Alternativamente, descrever um problema no espaço de projeto pode ser vantajoso de uma perspectiva visual quando o número de funções objetivo é relativamente grande.

2.3.4 Ótimo de Pareto

Em problemas de Otimização Multiobjetivo, diferentemente da otimização de problemas mono-objetivo, não existe uma solução global única e sim um conjunto de soluções que se encaixem em uma definição predeterminada para um ótimo. Em problemas de OMO o conceito de solução que predomina é o de otimalidade de Pareto [28]. Muitos fornecem uma definição formal para um ponto ótimo de Pareto em termos do espaço de projeto como segue [26, 27, 28]:

Definição 1 [Ponto ótimo de Pareto] Um ponto, $x \in X$, é ótimo de Pareto se e somente se não existe outro ponto, $x \in X$, tal que $F(x) \leq F(x^*)$, com pelo menos um $F_i(x) < F_i(x^*)$.

Um ponto é considerado ótimo de Pareto se não existir outro ponto que melhore o valor objetivo de ao menos uma função sem prejudicar qualquer outra função objetivo. Em outras palavras, não há como melhorar um ponto ótimo de Pareto sem aumentar

(se os objetivos são a minimização das funções) o valor de pelo menos uma das funções objetivo. Em geral, para um problema de OMO existem infinitos pontos ótimos possíveis e o subconjunto destes pontos que atendem à Definição 1 é chamado de conjunto ótimo de Pareto.

Matthias Ehrgott e Harold Benson [27] fornecem o seguinte teorema comum em termos do espaço de critério:

Teorema 1 [Teorema do contato] Um ponto, $F^* \in Z$, é Pareto ótimo se e somente se $Z \cap \gamma(F^*) = \{F^*\}$, onde $\gamma(F^*) \equiv \{F \in E^k | F = F^* + \delta, \delta \leq 0\}$

Para simplificar a notação, $F \equiv F(x)$ e $F^* \equiv F(x^*)$. O Teorema 1 sugere que se um ponto F^* no espaço critério é ótimo de Pareto, então é o único ponto no conjunto $\gamma(F^*)$ que também está no espaço critério viável Z . A única maneira de melhorar (reduzir simultaneamente todos os componentes de) um ponto ótimo de Pareto no espaço de critérios é violar as restrições. Da mesma forma, o teorema implica que todos os pontos ótimos de Pareto estão na fronteira do espaço de critério viável Z , uma característica que é confirmada na literatura ([26, 27]) e ilustrada na Figura 2.4.

Segundo Yann Collette e Patrick Siarry [26], todos os pontos ótimos de Pareto podem ser categorizados como sendo próprios ou impróprios conforme a defenição dada a seguir:

Definição 2 [Ótimo de Pareto Próprio] Um ponto, $x^* \in X$, é Ótimo de Pareto Próprio se for ótimo de Pareto e existe algum número real $M > 0$ tal que para cada $F_i(x)$ e cada $x \in X$ satisfazendo $F_i(x) < F_i(x^*)$, existe pelo menos um $F_j(x)$ tal que $F_j(x^*) < F_j(x)$ e $\frac{F_i(x^*) - F_i(x)}{F_j(x) - F_j(x^*)} \leq M$. Se um ponto ótimo de Pareto não é próprio, é impróprio.

Na Definição 2 a fração $\frac{F_i(x^*) - F_i(x)}{F_j(x) - F_j(x^*)}$ representa o *trade-off* entre as funções objetivo e expressa o incremento na função objetivo-j proveniente de um decréscimo na função objetivo-i. Esta definição impõe que o *trade-off* entre todas as funções objetivo seja limitado ($\leq M$).

Nem todos algoritmos conseguem fornecer soluções ótimas de Pareto, entretanto se conseguirem satisfazer outras condições menos restritivas, podem tornar-se significativas para aplicações práticas. Uma relaxação do conceito de otimalidade de Pareto, discutido em [27] é o conceito de Ótimo de Pareto Fraco definido a seguir:

Definição 3 [Ótimo de Pareto Fraco] Um ponto, $x^* \in X$, é fracamente Pareto ótimo se e somente se não existe outro ponto, $x \in X$, tal que $F(x) < F(x^*)$.

Pontos ótimos de Pareto são ótimos de Pareto fracos, mas pontos ótimos de Pareto fracos não são ótimos de Pareto. A otimalidade de Pareto fraca não é uma condição tão estrita quanto a otimalidade de Pareto padrão; é uma condição necessária para a otimalidade de Pareto.

2.3.5 Condições Necessárias e Suficientes

A ideia central para o desempenho de uma OMO específica é se resolvê-la serve como uma condição necessária e/ou suficiente para a otimalidade de Pareto. Diferentemente das otimizações de objetivo único, o desempenho de uma Otimização Multiobjetivo depende da modelagem da otimização. Caso ela forneça alguma condição necessária significa que para que um ponto possa ser considerado ótimo de Pareto, ele deve representar uma solução que atenda a esta condição. No entanto, algumas soluções para uma modelagem que fornece uma condição necessária podem não ser ótimas de Pareto. Em contrapartida, se uma modelagem de OMO fornece uma condição suficiente significa que suas soluções são sempre ótimas de Pareto. O que não significa que será capaz de capturar todos os pontos ótimos de Pareto.

Carlos A. Coello *et al.* [28] apresentam a seguinte condição prática de suficiência para um ponto ótimo de Pareto que é útil para avaliar a eficácia de métodos de escalarização:

Teorema 2 Seja $F \in \mathbb{Z}$, $x^* \in X$ e $F^* \equiv F(x^*)$. Seja $F_g(F) : \mathbb{Z} \rightarrow \mathbb{R}^1$ um critério global escalar que é diferenciável com $\nabla_F \cdot F_g(F) > 0 \forall F \in \mathbb{Z}$. Se $F_g(F^*) = \min\{F_g(F) | F \in \mathbb{Z}\} \Rightarrow x^*$ é ótimo de Pareto.

O Teorema 2 afirma que se qualquer variação por menor que seja (∇_F) de uma função global ($F_g(F)$) aumentar o valor objetivo (ou seja, piorar o resultado numa otimização cujo objetivo é a minimização) significa que ela é uma condição suficiente para a otimalidade de Pareto. O caminho inverso também é verdadeiro, ou seja, se x^* é um ponto ótimo de Pareto, então existe uma função $F_g(F)$ que satisfaz o Teorema 2 e encontra x^* .

2.3.6 Soluções de Consenso ou de Compromisso

Uma alternativa à ideia de otimalidade de Pareto é a ideia de uma solução de compromisso [26]. Este conceito fornece um único ponto de solução em vez de um conjunto de pontos assim como apresentado na proposta desta pesquisa no Capítulo 4. Uma solução de compromisso implica em minimizar a diferença entre o ponto ótimo potencial e o que é chamado de ponto utópico. O ponto da utopia é definido por Matthias Ehrgott e Harold Benson [27] da seguinte forma:

Definição 4 [Ponto de Utopia] Um ponto $F^U \in E^n$, no espaço de critérios, é um ponto de utopia se e somente se para cada $i = 1, 2, 3, \dots, n$, $F_i^U = \text{mínimo}_x\{F_i(x)|x \in X\}$.

Geralmente F^U é inviável, pois entre objetivos conflitantes é impossível otimizar totalmente cada função objetivo de forma simultânea e independente das outras funções. O ponto de utopia para o problema modelado na Equação 2.4 e ilustrado na Figura 2.3 situa-se no ponto de coordenadas (1.0, 0.3). Observe que não está em Z que é o espaço de critérios viável. A Definição 4 preconiza que uma solução próxima do ponto de utopia ($F_i^U = \text{mínimo}_x\{F_i(x)|x \in X\}$) é uma solução de compromisso. Embora as ideias de um ponto utópico e de uma solução de compromisso ocasionalmente sejam usadas em referência a conceitos de solução, como é o caso aqui, elas são mais prevalentes como facetas de métodos específicos que fornecem soluções ótimas de Pareto. De fato, uma solução de compromisso é ótima de Pareto.

A ideia de que uma solução de compromisso é uma solução próxima do ponto de utopia pode levar o leitor a uma ideia de redução da distância euclidiana $N(x)$, que é definida da seguinte forma:

$$N(x) = |F(x) - F^U| = \left\{ \sum_l^k [F_l(x) - F_l^U]^2 \right\}^{\frac{1}{2}} \quad (2.6)$$

No entanto, não há razão para restringir a proximidade ao caso de uma norma euclidiana [27]. Outro óbice da aplicação da norma euclidiana é que se as funções objetivo têm unidades diferentes, a norma torna-se insuficiente para representar matematicamente a proximidade. Conseqüentemente, as funções objetivo devem ser transformadas de forma que sejam adimensionais. Cada componente do argumento de soma em $N(x)$ deve ser dividido por F_i^U , resultando no que é chamado de desvio relativo de cada função [28].

2.4 Modelos de Predição de Sinal

Segundo Sverzut [29], a transmissão de uma onda eletromagnética pela interface de Rádio Frequência (RF) é um processo que envolve perdas *i.e.*, atenuação do sinal transmitido. Como a intensidade do campo elétrico cai inversamente com o quadrado da distância, quanto mais longe estiver o receptor do transmissor maior a atenuação. Os sistemas de radiotransmissão admitem a atenuação do sinal, desde que ele chegue em um nível mínimo tal que o receptor consiga entender o que o transmissor quer transmitir. Além da perda

em função da distância, também estão associados outros fatores como interferência de outras fontes e os ruídos atmosférico e térmico (gerados pelos componente eletrônicos dos equipamentos), os quais contribuem para a atenuação do sinal.

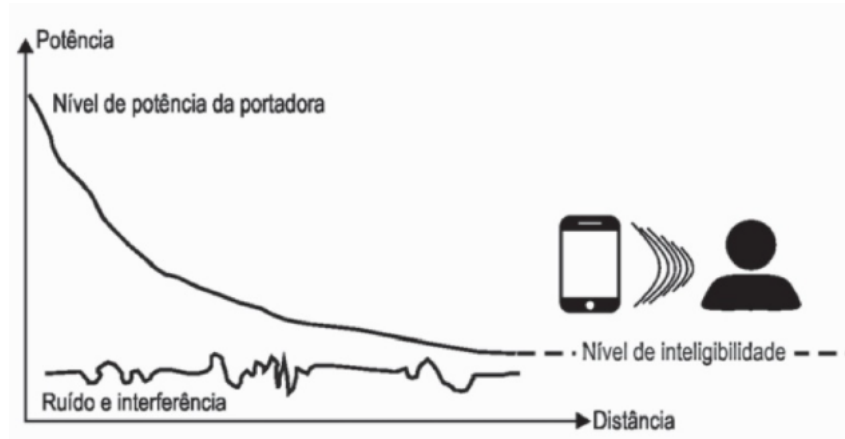


Figura 2.5: Transmissão do sinal de RF.
(Fonte: Svezut [29])

O nível de inteligibilidade, ilustrado na Figura 2.5, é o nível mínimo de recepção de um sinal com qualidade. Em outras palavras, esse nível é expresso pela relação sinal/ruído (do inglês, *Signal to Noise Ratio* (SNR)), conforme a seguinte equação:

$$SNR = 10 \cdot \log \left(\frac{P_{Sinal}}{P_{Ruído}} \right) [dB] \quad (2.7)$$

A Equação 2.7 demonstra que um sinal inteligível é aquele que apresenta um nível de potência maior que o de ruído, permitindo sua interpretação, reconhecimento e compreensão pelo receptor.

2.4.1 O canal de rádio difusão

Para Theodore Rappaport [2], a interface aérea e sem fio impõe limitações ao desempenho dos sistemas de comunicação que dependem deste meio. O percurso do sinal entre o transmissor e o receptor pode variar desde uma linha de visada LOS até obstruções por construções, árvores ou elevações naturais do terreno. Ele também descreve que os mecanismos relacionados à propagação de ondas eletromagnéticas são diversos, porém são provenientes de três fenômenos físicos característicos deste tipo de onda, que são: (i) a reflexão, (ii) a difração e (iii) o espalhamento.

- Reflexão: ocorre quando a onda eletromagnética propagada colide com objetos de dimensões superiores às do comprimento da onda propagada. Uma parte da energia

da onda é refletida, enquanto a outra é transmitida, penetrando no meio. As parcelas correspondentes às energias transmitidas e refletidas podem ser calculadas usando os coeficientes de transmissão que são dependentes das características do meio.

- **Difração:** Este fator físico ocorre quando o percurso entre o transmissor e o receptor é obstruído por uma superfície irregular. A incidência da onda sobre esta superfície gera ondas secundárias que são propagadas em várias direções inclusive atrás do obstáculo, causando a curvatura da onda e possibilitando que ela se propague fora da linha de visada LOS.
- **Espalhamento:** ocorre quando a onda eletromagnética propagada colide com objetos de dimensões inferiores às do comprimento da onda incidente e onde o número de obstáculos é grande. Essa situação ocorre devido à presença de estruturas pequenas e rugosas como folhagens e fios.

Segundo o *3rd Generation Partnership Project* em seu relatório técnico [30], nos ambientes terrestres, os efeitos da propagação RF são divididos em três tipos distintos que são: (i) o *Path Loss*, (ii) o desvanecimento lento e (iii) o desvanecimento rápido. O *Path Loss* ocorre devido a existência ou não de *Line Of Sight* (LOS), da distância entre o transmissor e o receptor e das características do relevo, clima e grau de urbanização da região em análise. Já o desvanecimento lento é consequência do sombreamento e do espalhamento do sinal. Enquanto o desvanecimento rápido é devido aos efeitos da propagação do sinal por múltiplos caminhos. No percurso entre o transmissor e o receptor, o sinal de Rádio Frequência sofre múltiplas reflexões, o que faz com que a onda percorra caminhos diversos com distâncias distintas. Ao chegar no receptor, onde estas ondas se recombinaem, ocorre um fenômeno chamado de desvanecimento de multipercurso, além da atenuação do nível do sinal em função da distância entre o transmissor e o receptor.

2.4.2 Planejamento da rede de RF - *Link Budget*

Segundo Seybold [31], o processo de planejamento do nível de sinal que deve chegar aos receptores de um sistema de comunicação recebe o nome de *link budget* e constitui-se da (i) potência de transmissão (P_{Tx}), (ii) ganho da antena de transmissão (G_{Tx}), (iii) perda de sinal pelo percurso, em inglês *Path loss* (L_{Path}) e (iv) ganho da antena de recepção (G_{Rx}), conforme a Equação 2.8.

$$LinkBudget = P_{Tx} + G_{Tx} - L_{Path} + G_{Rx} \quad (2.8)$$

O *link budget* representa o nível do sinal recebido pelos usuários do sistema e o seu valor esperado para que uma conexão seja estabelecida com sucesso depende da modulação utilizada, além dos fatores apresentados na Equação 2.8. A modulação afeta o *link budget* ao alterar a relação SNR e será tratada na Seção 2.5 em que é abordado a tecnologia 4G/LTE. Os ganhos das antenas, perdas de transmissão e potência transmitida são diretamente afetados pelo *link budget*. O *Path Loss* é o fator mais significativo devido à magnitude relativa em relação aos outros termos da Equação 2.8 e por isso será estudado em maiores detalhes nesta Seção. Maiores detalhes acerca do funcionamento, propriedades e ganhos das antenas são analisados por Constantine Balanis em [32].

2.4.3 Classificação dos Modelos

O planejamento de uma rede de RF é, portanto, diretamente impactado pela avaliação dos *link budgets* envolvidos. Como o principal fator nesta avaliação é o *Path Loss*, além deste ser o único fator variável da equação, mostra-se imprescindível defini-lo durante o planejamento da rede. É neste intuito que a literatura apresenta diversos modelos de predição de sinal e os classifica em teóricos, empíricos e mistos como vistos a seguir.

Teóricos

Os modelos de predição teóricos utilizam alguma formulação da teoria eletromagnética, como a Teoria Geométrica da Difração e a Teoria Uniforme da Difração, por exemplo, para realizar o cálculo de cobertura de uma região. A teoria escolhida pode ser inserida em uma técnica denominada Técnica de Traçado de Raios, que investiga as iterações do meio ambiente com o campo eletromagnético ao longo de raios que têm suas trajetórias ortogonais às frentes de onda. O uso da teoria eletromagnética confere aos modelos teóricos grande vantagem em termos de confiabilidade dos valores preditos. Além disso, outra característica favorável é o fato de que modelos dessa forma podem ser aplicados sem restrições aos tipos de ambientes. As principais desvantagens que podem ser citadas são a maior dificuldade de implementação em relação a modelos empíricos e a exigência de recursos computacionais significativamente maiores, em termos de memória e tempo de processamento.

Empíricos

Os modelos empíricos são obtidos a partir de campanhas de medições *in loco* em uma ou mais regiões, modelagem matemática dos resultados obtidos e apresentação do resultado final (modelo) através de tabelas e gráficos (como o modelo de Okumura, por exemplo) ou de expressões matemáticas que fornecem o valor mediano da atenuação esperada. Modelos

dessa categoria, em especial os modelos dados por uma expressão matemática, apresentam a vantagem de serem, em geral, de fácil aplicação e de necessitarem de um tempo de processamento computacional relativamente baixo. Em contrapartida, por serem baseados em medições reais realizadas em locais específicos, modelos empíricos tendem a não fornecer resultados muito confiáveis quando aplicados a regiões que difiram (em características como vegetação, clima, relevo, hidrografia e construções) significativamente da região original. Embora certos modelos apresentem adaptações para a predição em áreas de características globais distintas da original (como, por exemplo, o modelo de Hata-Okumura), os modelos empíricos são melhores adaptados a regiões de mesmas características da região onde foram realizadas as medidas.

Mistos

Os modelos mistos são os modelos de propagação mais utilizados para a implantação de sistemas de cobertura RF. Eles utilizam as perspectivas empíricas e teóricas, possuindo assim mais flexibilidade para que medidas reais realizadas no ambiente de propagação possam ser incorporadas ao modelo, minimizando o erro entre estimativa puramente teórica do sinal previsto e a realidade.

2.5 Sistema de telefonia 4G/LTE

O padrão LTE (do inglês, *Long Term Evolution*) foi especificado pela Organização 3GPP para melhorar o desempenho das redes WCDMA/HSPA⁺ (do inglês, *Wideband Code Division Multiple Access/High Speed Packet Access Plus*), padrões de acesso ao meio utilizados na geração anterior de rede celular, e ser a quarta geração (4G) de sistema de telefonia móvel, provendo um aumento nas taxas de transferência de dados nos sistemas de telefonia móvel celular de terceira geração (3G).

De modo geral e segundo Sverzut [29], os sistemas de telefonia celular operam no modo *full-duplex i.e.*, trabalham com dois canais: um de transmissão (Tx) e um de recepção (Rx). Cada canal é formado por uma portadora de Rádio Frequência e uma largura de faixa. A portadora representa a frequência alocada ao canal, enquanto a largura de faixa representa o espaço necessário para a transmissão da informação. De acordo com os requisitos operacionais do projeto CCOp Mv, a frequência portadora do sistema de telefonia 4G será de 700 MHz e a largura de faixa para transmissão das informações será de 20+20 MHz.

O 4^a Geração do Sistema de Telefonia Móvel também designada por Padrão de Longa Duração, do inglês *Long Term Evolution* (4G/LTE) é um sistema de telefonia celular de rede de acesso sem fio para longa distância, além disso, é uma tecnologia de banda

larga com padronização internacional podendo ser utilizada no contexto dos sistemas de comunicações de segurança pública conforme previsões do projeto CCOp Mv. Entre suas aplicações encontram-se aplicações com acesso à Internet, serviços de voz e serviços de dados. Todos fundamentados no protocolo de rede IP (do inglês, *Internet Protocol*). O 4G/LTE permite dados de banda larga móvel (aplicações e banco de dados), streaming de vídeo e comunicação de voz em tempo real, permitindo assim, economia de escala uma vez que a tecnologia é amplamente empregada no mundo por operadoras de celular. Os equipamentos dos usuários, do inglês *User Equipment* (UE), podem utilizar a infraestrutura de telefonia 4G celular para enviar/receber e-mail, navegar na Web, realizar transmissão de vídeo em tempo real, realizar videoconferências, baixar arquivos, enviar streaming de vídeo enquanto se deslocam, dessa forma visualiza-se obter um alto tráfego de dados em uma infraestrutura móvel com velocidades de até 350 km/h.

Por outro lado, o 4G/LTE possibilita alta taxa de *uplink* e *downlink* por setor – 7.5Mbps e 24Mbps, respectivamente, para canal de 5+5MHz – 100Mbps por site. Além disso, sua área de cobertura pode variar de 5 a 200 km² (varia com taxa de dados requerida, altura de antena e relevo) disponibilizando cerca de 1 a 8 km de raio por célula (área de cobertura de cada BTS).

Dois elementos importantes, representados na Figura 2.6 na arquitetura das redes LTE podem ser descritos como sendo:

1. Sistema de Rádio Terrestre: do inglês, *Evolved UMTS Terrestrial Radio Access Network* (E-UTRAN); e
2. Núcleo da Rede: do inglês, *Evolved Packet Core* (EPC).

O primeiro é composto pelos nós de rede *i.e.*, as estações transceptoras base (eNodeBs), os quais são responsáveis pela comunicação com os usuários do sistema UE, bem como por sua comunicação com o núcleo da rede. O Núcleo da Rede tem como característica exercer as funções de: (i) gerenciamento do Tráfego; (ii) roteamento da Comunicação e (iii) comunicação entre múltiplos protocolos, entre eles o IP e o ATM (do inglês, *Asynchronous Transfer Mode*).

Neste contexto, pode-se enumerar as seguintes características mais importantes:

- Velocidade de até 350 Mbps no DL (do inglês, *Downlink*) e de até 75 Mbps no UL (do inglês, *Uplink*) com mobilidade;
- Velocidade de 1 Gbps estacionário;
- Telefonia IP;
- Técnica de modulação OFDMA – (do inglês, *Orthogonal Frequency Division Multiplexing / Multiple Access*). A multiplexação por divisão de frequências ortogonais;

- Antenas tipo MIMO – *Multiple Input – Multiple Output*;
- Largura de banda compreendida entre 5 e 20 MHz; e
- Faixas de frequências em 700, 850, 1.800, 2.100 MHz para o Serviço Móvel Pessoal (SMP).

O padrão 4G apresentado pelo 3GPP tem inovações com relação ao 3G, o EPC é uma rede de núcleo simplificado em IP, que unifica a rede celular de voz comutada por circuitos separada e a rede celular de dados comutada por pacotes, é uma rede “toda em IP”, pois voz e dados são transportados em datagramas IP. O EPC possibilita a integração de vários tipos de redes de acesso por rádio, incluindo as redes de acesso legadas dos sistemas de segunda e terceira gerações (2G e 3G). Desta forma o EPC permite que estas redes se conectem ao núcleo da rede. Essa característica permite uma alta escalabilidade pois a tecnologia 4G/LTE pode formar redes heterogêneas aproveitando as arquiteturas 3G, 2G e até mesmo sistemas de comunicações sem fio não padronizados pelo 3GPP como a padrão IEEE 802.11 WiFi.

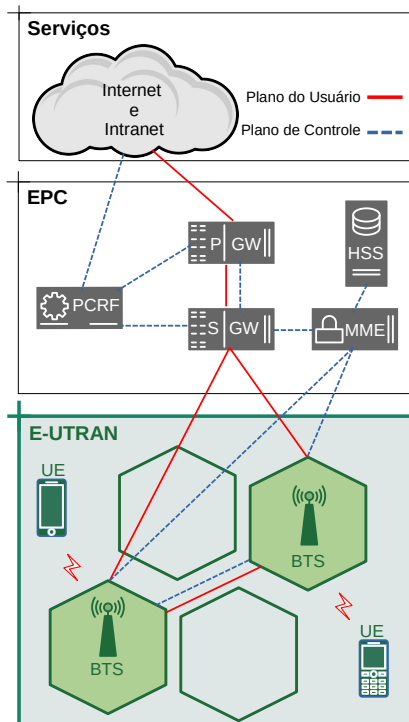


Figura 2.6: Arquitetura de um sistema 4G/LTE com destaque em verde para a camada em estudo.

(Fonte: o autor)

A arquitetura 4G, apresentada na Figura 2.6, combina muitos componentes funcionais para garantir autenticação e controle de acesso. Todos os componentes da rede 4G/LTE

operam com o mesmo protocolo da camada de rede (o protocolo IP) e comunicam entre si por meio de interfaces lógicas. Os principais componentes dessa rede são o UE, BTS (eNodeB), HSS e o MME. Cada um desses componentes da rede possuem atribuições bem definidas conforme descrição a seguir:

- UE (do inglês, *User Equipment*): um dispositivo móvel que inclui um UICC (cartão de circuito integrado universal, um cartão SIM) integrado com o USIM (módulo de identidade do assinante universal). O USIM armazena informações relacionadas ao usuário, como o IMSI (do inglês, *International Mobile Subscriber Identity*) que é usado para identificar cada cartão SIM de uma forma única e a chave secreta do assinante (que é pré-compartilhada com o AuC na rede doméstica e nunca deixa esses dois elementos).
- BTS - eNodeB (Evolved Node B): Consiste em uma antena e um conjunto de transceptores, é o principal componente da E-UTRAN.
- MME (do inglês, *Mobility Management Entity*): É o nó de controle da rede. Ele é responsável por realizar a autenticação, o rastreamento das localizações da UE e pela seleção dos *gateways* (definindo a rota dos pacotes de dados).
- HSS (do inglês, *Home Subscriber Server*): É um servidor de banco de dados que armazena os registros dos assinantes (contendo entre outros campos, suas identidades, direitos, perfis de assinatura e as chaves secretas). Ele também contém um Centro de Autenticação que controla o acesso criptografado dos usuários.
- S-GW (do inglês, *Serving Gateway*): ancora o portador de dados e roteia pacotes de dados para o UE.
- P-GW (do inglês, *Packet Data Network Gateway*): conecta à rede central do pacote às redes externas, como a Internet, e fornece endereços IP para UE.

O uso da tecnologia 4G/LTE no projeto CCOp Mv tem o propósito de ser a base das Comunicações Críticas durante as operações militares. As Comunicações Críticas são sistemas de comunicações que se utilizam de infraestruturas, fixas ou móveis, com elevada capacidade de sobrevivência e que geram áreas de cobertura, nas quais grupos de conversações definidos previamente dispõem de comunicações, de voz e dados, com possibilidade de comunicações ponto a ponto, com elevadas disponibilidade, confiabilidade e segurança, cuja principal característica é a capacidade de prover comunicação a serviços de missão crítica em prol do cidadão, usualmente chamados de Proteção Pública e Socorro a Desastres, tanto na Defesa, Segurança Pública, Defesa Civil e Fiscalização, Repressão

e Controle [33]. Para as Forças Armadas, tem como característica operar em locais isolados, fronteiras com Área Rural, longe de centros urbanos onde é comercialmente inviável a cobertura de operadoras comerciais.

Os principais serviços requeridos para a aplicação 4G/LTE para esses órgãos são os seguintes: *(i)* aplicativos de comando e controle com comunicação IP: eles permitem que um grande número de serviços sejam fornecidos, como, por exemplo, streaming de vídeo e comunicação de voz (PTT e VoIP) em tempo real; *(ii)* mobilidade em operações táticas: podem ser utilizadas plataformas móveis veiculares como apoio táticos, com possibilidade de prover temporariamente cobertura em uma determinada região que necessite de comunicação crítica fornecendo aplicações de voz em grupo, videoconferência, vídeo em tempo real, utilização de aplicativos de comando e controle; *(iii)* atuação em locais isolados: gerenciamento centralizado de desempenho de missão crítica e indicadores de disponibilidade otimizados modelos de chamadas através de redes de rádio; *(iv)* gerenciamento de operações: gerenciamento centralizado de performance de missão crítica e indicadores de disponibilidade otimizados para modelos de chamadas de missão crítica e utilização através de redes de rádio, LTE, aplicações e dispositivos – modelo de multi-agência; *(v)* priorização e controle em tempo real: o núcleo do 4G/LTE irá gerenciar priorização, controle e garantia de serviço de nível missão crítica que não pode ser satisfeito com sistemas de nível comercial das operadoras.

2.6 Considerações Parciais

Neste capítulo, foram abordados os principais conceitos para fornecer subsídios a esta Dissertação. Em razão disso, foi dado uma maior ênfase na técnica de Programação Linear, bem como nos métodos de otimização discretos e de multiobjetivo que estão diretamente relacionados com esta pesquisa. A partir dos conceitos apresentados, os principais desafios a serem superados de cada tema foram elencados. Além disso, convém salientar que algumas características particulares de cada tema, tais como parâmetros, métodos e considerações, serão apresentados e justificados no Capítulo 4. No próximo capítulo, serão apresentados os trabalhos relacionados a esta proposta de pesquisa com o intuito de identificar e validar as lacunas deste tema na literatura.

Capítulo 3

Trabalhos Relacionados

Este capítulo apresenta as abordagens que exploram o problema do MCLP no contexto do SAD. O MCLP foi inicialmente explorado por [12], resultando no desenvolvimento de modelos voltados a cobrir o maior número de pontos de demanda. Atualmente, o MCLP está sendo investigado, adicionando novas funcionalidades ao problema, tais como energia de transmissão, perda de sinal, tempo de processamento, bem como a utilização de novos algoritmos heurísticos e meta-heurísticos para solucionar o problema.

3.1 Análise dos Trabalhos Relacionados

Em [3] é proposto o uso de uma meta-heurística baseada em um algoritmo memético, que é uma derivação de Algoritmo Genético (AG), para resolver o problema de localização de BTS. O trabalho aborda detalhes como o cálculo do alcance das antenas e a perda de caminho, a perda de força do sinal devido à degradação da distância. Ele determina a quantidade mínima de BTSs necessária para cobrir uma determinada região geográfica. Esta pesquisa apresenta algumas limitações, entre elas o fato de suas análises serem restritas a uma única solução meta-heurística, o que por natureza não garante a otimalidade dos resultados. Além das simplificações de domínio, a solução meta-heurística proposta não garante a melhor solução para o problema.

Atta *et al.* [4] visam acelerar o processo de solução de convergência usando AG. Sua solução é baseada em um processo de agrupamento, promovendo trocas cromossômicas dentro dos arranjos de agrupamentos. A convergência de suas soluções determina o número e a localização das instalações para permitir a cobertura do serviço para todos os clientes. Em [5], os autores abordam o problema de encontrar cobertura máxima em multiperíodos. Usando abordagens de AG e colônia de abelhas, os autores otimizam sua solução em termos de tempo de convergência e aplicam o *solver* Lingo para o modelo ana-

lítico matemático proposto. No entanto, tais abordagens são restritas à solução MCLP sem considerar uma aplicação específica.

Em [6], dois modelos matemáticos baseados no Problema de Cobertura de Conjunto, do inglês *Set Covering Problem* (SCP), são apresentados para resolver o problema de posicionamento de gNodeBs no contexto de redes de sensores sem fio suportando redes da 5ª Geração do Sistema de Telefonia Móvel (5G). O primeiro modelo visa minimizar o custo de implementação, enquanto o segundo maximiza a cobertura. Suas propostas são validadas por meio de simulações baseadas em métricas de velocidade sem considerar a qualidade ou confiabilidade dos resultados obtidos. Os dois modelos propostos abordam o SCP considerando a infraestrutura de rede pré-existente, restringindo sua aplicação a cenários específicos associados às redes 5G.

Outros estudos relacionados que merecem ser mencionados são propostos em [8] e [11]. Esses estudos exploram o MCLP considerando equipamentos com diferentes capacidades, também conhecidos como MCLP Capacitados (C-MCLP). Em [8], três soluções para o problema são propostas: uma solução exata, uma solução heurística e uma meta-heurística baseada em AG. Os hiperparâmetros são discretizados e seus valores ótimos são definidos pelo método de Taguchi. Os resultados são validados considerando os valores objetivos alcançados pelas soluções e respectivos tempos de processamento. As comparações são restritas a soluções propostas sem qualquer *benchmark*. Em [11], o C-MCLP é estudado na sob a ótica de suas restrições. Dois limites superiores calculados por decomposição Lagrangiana são propostos para resolver o problema, e dois limites inferiores são derivados deles. Os resultados demonstram que utilizando os limites propostos ao MCLP obtém-se melhor desempenho. Pela característica intrínseca de soluções exatas, esta proposta restringe-se a ser aplicada a cargas de trabalho de pequeno porte.

A pesquisa que mais se assemelha à esta é apresentada em [7]. Ela explora o problema de localização para a cobertura contínua máxima. Os autores propõem dois modelos matemáticos baseados em programação linear inteira para casos de um e vários períodos, considerando um cenário dinâmico com movimentação de veículos de comunicação para situações de resgate em cenários de desastres naturais. Os modelos são validados por meio de simulações baseadas em soluções exatas desenvolvidas no *solver* CPLEX. A eficiência dessas soluções é avaliada por meio de comparações com os resultados obtidos pelo algoritmo de agrupamento k-means. Em tal trabalho, a aplicação considerada é apenas teórica devido à limitação do cenário proposto. Ainda, considera apenas as coordenadas cartesianas de UEs, BTSs e suas respectivas distâncias, sem utilizar modelos de previsão de sinal ou parâmetros de simulação definidos pelo 3GPP. Vale ressaltar que essas soluções apenas determinam o número e a localização das BTSs sem considerar a possibilidade de variação do parâmetro de potência de transmissão.

3.2 Discussão dos Trabalhos Relacionados

Com base nos trabalhos relacionados, a Tabela 3.1 apresenta um resumo comparativo entre esta dissertação e os demais da literatura. A Tabela 3.1 apresenta as técnicas exploradas em cada um destes trabalhos, além de novas contribuições que destacam esta pesquisa que foram adicionadas. De acordo com nossa pesquisa, apenas dois trabalhos ([5] e [8]) realizaram a comparação das soluções meta-heurísticas com a solução ótima. Também é fundamental notar o ajuste de parâmetros e métodos pouco explorados na literatura, identificados apenas nos trabalhos de [4] e [8]. Todos os trabalhos analisados tem um único objetivo de otimização e visam encontrar uma solução com área de cobertura máxima [3, 4, 5, 6, 7, 8, 11] ou a menor interferência entre as células [14] e [15].

Tabela 3.1: Comparação com os trabalhos relacionados.

Trabalho	Modelagem matemática	Solução exata	Heurísticas ou Meta-heurísticas	Ajuste dos hiperparâmetros	Métricas de qualidade	Métricas de velocidade	Métricas de confiabilidade	Minimização da interferência	Maximização da cobertura	Potência de Tx variável
[3]	✓		✓			✓			✓	
[4]	✓			✓	✓	✓			✓	
[5]	✓	✓	✓		✓	✓			✓	
[14]								✓		✓
[34]									✓	✓
[35]	✓	✓							✓	
[15]								✓		✓
[6]	✓	✓							✓	
[7]	✓	✓			✓	✓			✓	
[8]	✓	✓	✓	✓	✓	✓			✓	
[11]	✓								✓	
Dissertação	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

3.3 Considerações Parciais

Diante das discussões apresentadas acima, nosso trabalho considera a implantação de redes 4ª Geração do Sistema de Telefonia Móvel também designada por Padrão de Longa Duração, do inglês *Long Term Evolution* (4G/LTE) militarizadas em ambientes sem infraestrutura pré-existente e com características de alta mobilidade. Também considera soluções de otimização multiobjetivo, fornecendo modelagem de cenários para alocação

de recursos geograficamente distribuídos e um modelo analítico baseado em Programação Linear Inteira Mista. O modelo analítico fundamentou a proposta de duas soluções otimizadas, que fornecem subsídios para a construção do módulo de otimização proposto para o SAD do CCOp Mv, conforme apresentado no capítulo a seguir.

Capítulo 4

Soluções otimizadas em redes militarizadas 4G/LTE

Este capítulo apresenta um sistema de apoio à decisão do CCOp Mv para solucionar o problema de posicionamento e configuração de suas BTSs em regiões onde a infraestrutura de comunicação é precária ou mesmo inexistente na perspectiva de uma rede 4G/LTE. Assim, foram modeladas duas soluções otimizadas para lidar com o problema MCLP no contexto do CCOp Mv, a saber: (i) E-ALLOCATOR, que é uma solução exata baseada em PLIM; e (ii) M-ALLOCATOR, que é uma solução meta-heurística de natureza combinatoria baseada em AG. O principal objetivo do serviço proposto é determinar o número de veículos necessários e otimizar sua localização geográfica e sua respectiva potência de transmissão a ser definida, de forma a maximizar a área de cobertura com a menor interferência entre as BTSs, ao mesmo tempo em que proporciona uma maior área de suporte nas operações que necessitam comunicação crítica.

4.1 Sistema de Apoio à Decisão do CCOp Mv

A Figura 4.1 apresenta o cenário de funcionamento do sistema proposto no processo de alocação dos nós do CCOp Mv. A ideia desta proposta surgiu do CCOp Mv, cujo objetivo é fornecer os meios de comando e controle necessários para a coordenação das operações do Exército Brasileiro. O CCOp Mv é um projeto do Programa Proteger [33] que visa suprir a Força Terrestre da Infraestrutura de Tecnologia da Informação e Comunicações (TIC) necessária para apoiar as operações terrestres em ambientes sem infraestrutura de comunicação. O CCOp Mv é composto por cinco caminhões de 5 toneladas que formam o Conjunto de Coordenação de Operações e até oito veículos de duas e meia toneladas denominados nós de acesso. Esses veículos operam em conjunto e, portanto, neste trabalho são considerados como ocupantes de uma única posição de alocação. Todos esses

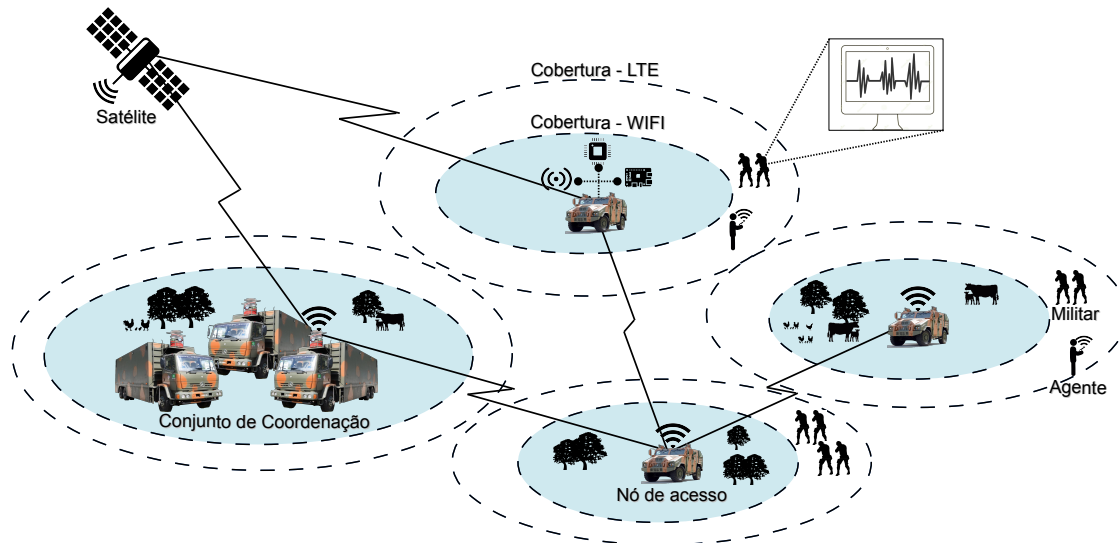


Figura 4.1: Cenário de funcionamento do Sistema de Apoio à Decisão do CCOp Mv.
(Fonte: o autor)

veículos fornecem uma plataforma de comunicação formada pelas seguintes tecnologias: rede de rádio celular 4G/LTE militarizada; rádios *Ultra High Frequency* (UHF), *Very High Frequency* (VHF) e *High Frequency* (HF); Sistema de Rádio Digital Troncalizado (SRDT); e equipamentos com acesso ao Sistema Militar de Comunicações por Satélite e Sistemas de Comando e Controle para Conhecimento Situacional e Apoio à Decisão. As soluções apresentadas neste trabalho para o posicionamento e configuração das BTSs vão além da questão científica da resolução do problema em si, mas também passam pela sua aplicação prática no âmbito do CCOp Mv.

O SAD proposto foi dividido em duas etapas: (i) pré-processamento; e otimização (ii). Na etapa de pré-processamento, ilustrada na Figura 4.2, os pesos e matrizes de conectividade são gerados por meio de dados geográficos do terreno, como latitude, longitude e elevação. Estas informações são utilizadas para determinar se existe linha de visada, do inglês, *Line Of Sight* (LOS) entre a posição geográfica dos nós de acesso (as BTSs) e os usuários do sistema (os UEs). Além disso, também são consideradas as características de propagação do sinal sem fio, interferência, relação sinal-ruído, do inglês *Signal to Noise Ratio* (SNR), desvanecimento do sinal, potência de transmissão e recepção, bem como seus limites de aceitação para definir a eficácia da comunicação dos enlaces rádio.

A etapa de pré-processamento foi estruturada nos modelos de simulação propostos pelo 3GPP em seus Relatórios Técnicos TR-36.814 [30] e TR-36.872 [36] que adotam diferentes modelos de predição de acordo com às distâncias entre UEs e BTSs, além de outras características como a existência ou não de LOS.

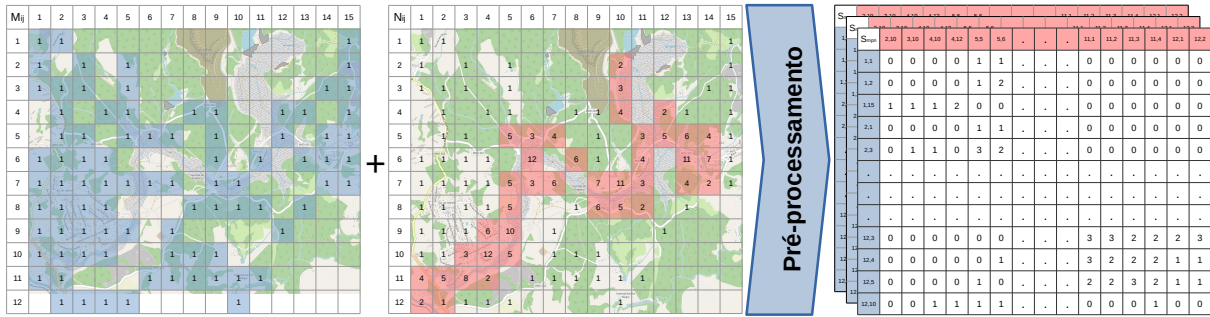


Figura 4.2: Etapa de Pré-processamento do SAD do CCOP Mv.
(Fonte: o autor)

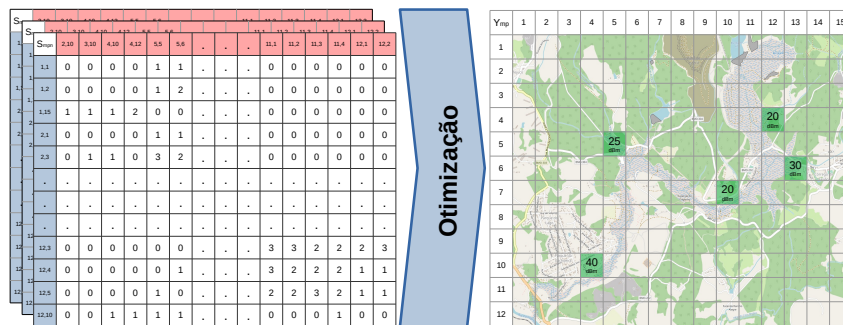


Figura 4.3: Etapa de Otimização do SAD do CCOP Mv.
(Fonte: o autor)

As informações obtidas, analisadas e trabalhadas nesta fase do modelo servem de entrada para a segunda etapa da solução, a fase de otimização, ilustrada na Figura 4.3. Nesta etapa, as soluções propostas E-ALLOCATOR e M-ALLOCATOR utilizam as informações de pré-processamento para definir a quantidade, as localizações em que os nós de acesso devem ser posicionados e as potências de transmissão que devem ser configuradas em cada BTS, para permitir uma maior área de cobertura com a menor interferência possível para o sistema 4G/LTE.

4.2 Modelo do Sistema

Nesta seção, são apresentadas a modelagem matemática do SAD e a formulação do problema de otimização adotado. O problema foi modelado a partir da possível associação entre UEs e BTSs que serão instalados em diferentes posições geográficas. A Tabela 4.1 apresenta as notações usadas na modelagem e definição do problema.

A modelagem é baseada em Programação Linear Inteira Mista e é iniciada pela definição do conjunto $\mathcal{M} = \{m_{11}, m_{12}, \dots, m_{1j}, m_{21}, m_{22}, m_{2j}, \dots, m_{i1}, m_{i2}, \dots, m_{ij}\}$ de nós que representam os possíveis locais para instalação das BTSs e o conjunto $\mathcal{N} = \{n_{11}, n_{12},$

Tabela 4.1: Notação utilizada nesta obra.

Notação	Parâmetro
$G(\mathcal{M} \cup \mathcal{N}, S)$	Grafo do sistema
\mathcal{M}	Conjunto de posições aptas à implantação de uma BTS
\mathcal{N}	Conjunto de posições de concentração de demanda
\mathcal{P}	Conjunto de potências de transmissão disponíveis em uma BTS
m_{ij}	Uma posição $\in \mathcal{M}$ apta à implantação de uma BTS e delimitada pelas coordenadas (linha, coluna) = (i, j)
n_{ij}	Número de usuário (UEs) na quadrícula $\in \mathcal{N}$ de coordenadas (linha, coluna) = (i, j)
p	Uma potência de transmissão das BTSs $\in \mathcal{P}$
$\varsigma(m_{ij}, p, n_{rs})$	Função de conexão entre uma BTS em m_{ij} com potência de transmissão p e os UEs em n_{rs}
S	Matriz de adjacências ou conjunto de arestas
s_{mpn}	Aresta ponderada $\in S$ entre uma BTS em m com potência de transmissão p e os UE em n
C	Matriz de conectividade entre as BTSs e os UEs
c_{mpn}	Aresta binária $\in C$ entre uma BTS em m com potência de transmissão p e os UEs em n
x_n	Variável de decisão da posição de demanda n
y_{mp}	Variável de decisão da posição de implantação de BTS m com potência de transmissão p
z_{mn}	Variável de decisão da associação entre uma BTS em m com os UEs em n
$G'(\mathcal{M}, A)$	Grafo de interconexão entre as BTSs
A	Matriz de conectividade entre as BTSs
a_{mpk}	Aresta binária $\in A$ entre uma BTS em m com potência de transmissão p e uma BTS em k
Γ_{mp}	Grau de impacto na interferência do sistema causada pela implantação de uma BTS na posição m com potência de transmissão p
ϕ	Número máximo de BTSs a serem implantadas
ψ	Número máximo de UEs suportados por BTS
ξ	Número mínimo de BTSs interconectadas
ρ	Consenso de cobertura mínimo

... , $n_{1j}, n_{21}, n_{22}, n_{2j}, \dots, n_{i1}, n_{i2}, \dots, n_{ij}$ de nós que representam as localizações dos clientes ou UEs do sistema de comunicação. Cada par de nós (m_{ij}, n_{rs}) forma uma aresta conectada quando $\{m_{ij} \in \mathcal{M}, p \in \mathcal{P} \text{ e } n_{rs} \in \mathcal{N} \mid \varsigma(m_{ij}, p, n_{rs}) \neq 0\}$, no qual $\varsigma(m_{ij}, p, n_{rs})$ representa a função de conexão e recebe os valores inteiros entre 1 e 3 que denotam o intensidade do sinal recebido, quando a posição dos clientes n_{rs} puder ser atendida pela BTS localizada na posição m_{ij} com a potência de transmissão p configurada na BTS, e 0 caso contrário. A função de conexão deve ser iterada considerando as combinações

entre todos os nós \mathcal{M} com todas as potências de transmissão disponíveis em \mathcal{P} e com todos os nós \mathcal{N} para gerar a matriz de adjacência $S_{M \times P \times N}$ que determina a conjunto de arestas deste sistema, onde cada elemento $s_{mpn} \in \{0, 1, 2, 3\}$. Do conjunto de arestas S é derivada a matriz de conectividade binária C que tem as mesmas dimensões, mas com valores binários. Seja $s_{mpn} \in S$ e $c_{mpn} \in C$, esta derivação segue o seguinte critério:

$$c_{mpn} = \begin{cases} 1, & \text{se } s_{mpn} > 0; \\ 0, & \text{caso contrário.} \end{cases}$$

Portanto, nosso serviço pode ser definido pelo grafo bipartido $G(\mathcal{M} \cup \mathcal{N}, S)$.

O grafo $G'(\mathcal{M}, A)$, que modela as conexões entre as BTSs, é definido de forma análoga, porém os vértices são apenas elementos do conjunto \mathcal{M} . Os pesos de suas arestas também são determinados pela iteração da função de conexão $\varsigma(m_{ij}, p, k_{rs})$, para m e $k \in \mathcal{M}$ e $p \in \mathcal{P}$, pelas $n(P)$ permutações dos nós do conjunto \mathcal{M} , gerando assim a matriz de adjacência deste subsistema, que é convertida na matriz de conectividade entre as BTSs $A_{M \times P \times M}$, com elementos $a_{mpk} \in \{0, 1\}$ semelhante à conversão de S para C no grafo do sistema.

4.3 Definição do Problema

Nesta seção, o problema de localização dos nós de acesso do CCOp Mv e definição das configurações de suas BTSs será decidido como uma extensão do MCLP. Para isso, definimos as variáveis de decisão, restrições e objetivos do MCLP, e então propomos um problema de Programação Linear Inteira Mista. As variáveis de decisão definidas e seus significados são dados por:

$$x_n = \begin{cases} 1, & \text{se a posição de UEs } n \text{ for servida por alguma BTS que lhe dê cobertura;} \\ 0, & \text{caso contrário.} \end{cases}$$

$$y_{mp} = \begin{cases} 1, & \text{se a posição } m \text{ foi escolhida para ter uma BTS instalada} \\ & \text{com a potência de transmissão } p; \\ 0, & \text{caso contrário.} \end{cases}$$

$$z_{mn} = \begin{cases} 1, & \text{se a posição de UEs } n \text{ foi designada para ser} \\ & \text{servida por uma BTS instalada em } m; \\ 0, & \text{caso contrário.} \end{cases}$$

Para a construção do nosso modelo, foram determinadas dez restrições conforme apresentada a seguir:

- *Restrição 4.1* - Define que para uma posição de clientes n (x_n) ser atendida, é necessário que ao menos uma BTS na posição m com a potência de transmissão p configurada (y_{mp}) e que lhe forneça cobertura seja instalada:

$$\sum_{m \in \mathcal{M}} \sum_{p \in \mathcal{P}} y_{mp} \cdot c_{mpn} \geq x_n, \forall n \in \mathcal{N} \quad (4.1)$$

onde c_{mpn} terá o valor 1, se a BTS na posição m com a potência de transmissão p for capaz de cobrir o usuário na posição n .

- *Restrição 4.2* - Define que cada posição de UEs n só pode ser atendida ou associada ($z_{mn} = 1$) a apenas uma BTS m .

$$\sum_{m \in \mathcal{M}} z_{mn} = x_n, \forall n \in \mathcal{N} \quad (4.2)$$

- *Restrição 4.3* - Cada BTS na posição m pode atender a um número máximo de usuários (ψ) associados a ela ($\sum_{n \in \mathcal{N}} z_{mn} \cdot n_{ij}$). O número máximo de usuários é um parâmetro específico da BTS e pode variar significativamente de um fabricante para outro. Além disso, este parâmetro é influenciado por sua largura de banda operacional, pelo fator de utilização esperado e pela capacidade de *downlink* e *uplink* desejada para cada usuário.

$$\sum_{n \in \mathcal{N}} z_{mn} \cdot n_{ij} \leq \psi, \forall m \in \mathcal{M} \quad (4.3)$$

- *Restrição 4.4* - Define que as posições de UEs n só podem ser associadas a BTSs instaladas ou ativadas em qualquer posição m ($\sum_{p \in \mathcal{P}} y_{mp} = 1$). Se nenhuma BTS

estiver instalada em m ($\sum_{p \in \mathcal{P}} y_{mp} = 0$), então não devem haver UEs associados a ela ($\sum_{n \in \mathcal{N}} z_{mn} \cdot n_{ij} \leq 0$).

$$\sum_{n \in \mathcal{N}} z_{mn} \cdot n_{ij} \leq \sum_{p \in \mathcal{P}} y_{mp} \cdot \infty, \forall m \in \mathcal{M} \quad (4.4)$$

- *Restrição 4.5* - Estabelece que o número de BTSs instaladas não deve exceder o número máximo disponível (ϕ).

$$\sum_{m \in \mathcal{M}} \sum_{p \in \mathcal{P}} y_{mp} \leq \phi \quad (4.5)$$

- *Restrição 4.6* - A rede móvel deve estar sempre conectada para fornecer serviços. Como as BTSs são transportadas por nós móveis, elas devem participar de uma rede entre si para o escoamento de dados. Por exemplo, na minuta do projeto CCOp Mv, afirma-se que um nó de acesso deve se conectar a pelo menos 3 outros nós para operação correta. Neste caso, uma BTS (y_{mp}) deve se conectar a no mínimo (ξ) outras BTSs caso elas possam se interconectar ($a_{mpk} = 1$).

$$\sum_{k \in \mathcal{M}} \sum_{l \in \mathcal{P}} y_{kl} \cdot a_{mpk} \geq y_{mp} \cdot (\xi + 1),$$

$$\forall m \in \mathcal{M} \text{ e } \forall p \in \mathcal{P} \quad (4.6)$$

- *Restrição 4.7* - Define que uma BTS m pode ter apenas uma potência de transmissão p ativada.

$$\sum_{p \in \mathcal{P}} y_{mp} \leq 1, \forall m \in \mathcal{M} \quad (4.7)$$

- *Restrição 4.8* - Natureza binária da variável de decisão x_n .

$$x_n \in \{0, 1\}, \forall n \in \mathcal{N} \quad (4.8)$$

- *Restrição 4.9* - Natureza binária da variável de decisão y_{mp} .

$$y_{mp} \in \{0, 1\}, \forall m \in \mathcal{M} e \forall p \in \mathcal{P} \quad (4.9)$$

- *Restrição 4.10* - Natureza binária da variável de decisão z_{mn} .

$$z_{mn} \in \{0, 1\}, \forall m \in \mathcal{M} e \forall n \in \mathcal{N} \quad (4.10)$$

Diante do exposto, nosso modelo matemático tem dois objetivos:

1. Na Equação 4.11: Maximizar a área de cobertura do sistema LTE do CCOp Mv, onde $\top(s_{mnp})$ é o maior valor da função de conexão entre as BTSs instaladas (y_{mp}) e os n_{ij} UEs atendidos da rede. Isso condiz com a realidade, pois os aparelhos se associam ao BTS que lhe fornece o sinal mais forte; e
2. Na Equação 4.12: Minimizar interferências entre BTSs implantadas, causadas pela sobreposição de seus sinais, para reduzir a degradação da qualidade do serviço e indiretamente empregar um menor número de veículos, promovendo economia em recursos financeiros.

$$\text{Max} \left(\frac{1}{\ddot{c}} \right) \cdot \sum_{n=1}^N n_{ij} \cdot \top(s_{mnp}) \cdot x_n, \quad (4.11)$$

$$\text{Min} \left(\frac{1}{\ddot{i}} \right) \cdot \sum_{m=1}^M \sum_{p=1}^P \Gamma_{mp} \cdot y_{mp} \quad (4.12)$$

Onde \ddot{c} é a diferença entre o valor máximo e mínimo da equação $\sum_{n=1}^N n_{ij} \cdot \top(s_{mnp}) \cdot x_n$ e \ddot{i} é a diferença entre os valores extremos obtidos na equação $\sum_{m=1}^M \sum_{p=1}^P \Gamma_{mp} \cdot y_{mp}$. Este processo consiste em normalizar as equações para que os valores objetivos variem entre $[0,1]$ para a Equação 4.11 e $[-1,0]$ para a Equação 4.12.

4.4 Soluções Otimizadas

A modelagem analítica do problema de alocação e configuração das BTSs do CCOp Mv, baseada em PLIM, serviu de base para as soluções propostas E-ALLOCATOR e M-ALLOCATOR.

4.4.1 E-ALLOCATOR

Com o objetivo de percorrer todo o espaço de busca, foi proposto o E-ALLOCATOR, uma solução exata baseada no algoritmo *Branch and Bound* (BB) para PLIM, como apresentado no Algoritmo 1. Para tanto, na inicialização do Algorithm 1, a função objetivo é carregada com a Equação 4.12 (linha 4), juntamente com todas as restrições da definição do problema (linha 5). Por se tratar de uma otimização multiobjetivo, o que se busca é uma solução de consenso entre as Equações 4.11 e 4.12. Este consenso entre as duas soluções é definido como uma solução ótima de Pareto. A estratégia empregada para encontrar as soluções ótimas de Pareto para este problema foi a conversão da Equação Objetivo 4.11 em mais uma restrição para definir uma taxa de cobertura mínima ρ (linha 6). Além disso, as variáveis que armazenam o melhor valor objetivo Obj^* e a melhor solução y_{mp}^* já avaliadas são instanciadas com o valor $-\infty$ e com o conjunto vazio \emptyset , respectivamente (linha 7). Antes de começar a procurar a melhor solução ou solução ótima, um nó aleatório da árvore de busca é carregado na matriz de soluções y_{mp} (linha 8). Sua geração é aleatória mas deve respeitar as restrições já carregadas. A partir deste nó, e utilizando o método de busca por ponto inteiro, também conhecido como método Simplex (linha 9), é feita uma varredura de toda a árvore de busca (linhas 10 a 28). Em seguida, analisa as soluções que atendem às restrições do modelo apresentado na Seção 4.3, excluindo soluções inviáveis, *i.e.*, que não atendem às restrições (linhas 12 e 13), ou que apresentam resultados inferiores aos já analisados (linhas 15 e 16). Por se tratar de uma variável inteira, os resultados obtidos de forma relaxada, *i.e.*, $y_{mp} \notin \mathbb{Z}_+$ são subdivididos novamente (linhas 18 a 22) e então o processo é repetido. Neste caso, a relaxação linear do modelo é dada pelo limite superior. A solução desenvolvida utilizou o solver CBC-MIP do framework ORTools [37].

4.4.2 M-ALLOCATOR

Por se tratar de um problema de otimização NP-Completo, soluções exatas tendem a ser obtidas em um período aceitável apenas para instâncias cuja carga de trabalho do problema é pequena. Para sanar essa limitação, foi proposto o M-ALLOCATOR, que é uma meta-heurística que visa encontrar uma boa solução, *i.e.*, uma solução subótima,

Algoritmo 1: E-ALLOCATOR

```
1 Entrada:  $S, C, A, \mathcal{M}, \mathcal{N}, \mathcal{P}, \phi, \psi, \xi, \rho$ 
2 Saída: Matriz  $y_{mp}^*$  com as localizações ótimas e respectivas configurações das
   BTSs.
3 Inicialize:
4    $Obj(y_{mp}) \leftarrow \{\text{Equação Objetoivo 4.12}\}$ 
5   Restrições  $\leftarrow \{\text{Restrições 4.1 a 4.10}\}$ 
6   Restrições  $\leftarrow \{\text{Equação Objetoivo 4.11} = \rho\}$ 
7    $Obj^* \leftarrow -\infty$  e  $y_{mp}^* \leftarrow \emptyset$ ;
8    $y_{mp} \leftarrow$  Nó aleatório da árvore de busca;
9   Resolve o problema pelo método Simplex;
10 while  $\exists$  sub-problemas a serem investigados do
11   Resolve os 2 subproblemas pelo método Simplex;
12   if subproblema é inactivível then
13     Descarte-o;
14   else
15     if  $Obj(y_{mp}) \leq Obj^*$  then
16       Descarte-o;
17     else
18       if  $Obj(y_{mp}) \notin \mathbb{Z}_+$  then
19         Escolhe  $y_{mp}$  que tem valor  $\neq \{0, 1\}$  em  $y_{mp}$ ;
20         Cria 2 novos subproblemas acrescentando as restrições:
21            $y_{mp} = 0$  para o primeiro subproblema e
22            $y_{mp} = 1$  para o segundo subproblema;
23       else
24          $Obj^* \leftarrow Obj(y_{mp})$ ; e  $y_{mp}^* \leftarrow y_{mp}$ ;
25       end
26     end
27   end
28 end
29 return  $y_{mp}^*$ 
```

baseada em um AG, conforme apresentado no Algoritmo 2. Ele é inicializado por meio da instanciação de uma população inicial de forma aleatoria (linha 8). Em seguida, obtém-se o grau de adaptação de cada indivíduo aplicando a função de aptidão *BFit* (linha 10). Se o grau de adaptação do indivíduo mais adaptado encontrado na geração atual for melhor que o da geração anterior, os valores da melhor aptidão e do indivíduo mais adaptado são armazenados para futuras comparações (linhas 11 a 13). Assim, é realizado o processo evolutivo do AG, que é a aplicação dos métodos de seleção (linha 17), reprodução (linha 18) e mutação (linha 19) para a composição da próxima geração (linha 20). A solução desenvolvida utilizou a biblioteca PyGAD [38].

Algoritmo 2: M-ALLOCATOR

```
1 Entrada:  $S, C, A, \mathcal{M}, \mathcal{N}, \mathcal{P}, \phi, \psi, \xi, \rho$ 
2 Saída: Indivíduo  $y_{mp}^*$  com as localizações e respectivas configurações das BTSs
   que resultaram no melhor grau de adaptação.
3 Inicialize:
4    $BFit(y_{mp}) \leftarrow \{\text{Equação Objetivo 4.12}\}$ 
5   Restrições  $\leftarrow \{\text{Restrições 4.1 a 4.10}\}$ 
6   Restrições  $\leftarrow \{\text{Equação Objetivo 4.11} = \rho\}$ 
7    $BFit^* \leftarrow -\infty$  e  $y_{mp}^* \leftarrow \emptyset$ ;
8 Gere aleatoriamente a população inicial;
9 for  $geração=1$  a  $g$  do
10 |   Calcule o grau de adaptação de cada indivíduo da população atual;
11 |   if melhor grau de adaptação na geração atual  $\geq Obj^*$  then
12 |     |  $BFit^* \leftarrow$  melhor grau de adaptação da geração atual;
13 |     |  $y_{mp}^* \leftarrow$  individuo com o melhor grau de adaptação;
14 |   else
15 |     | Mantenha os  $BFit^*$  e  $y_{mp}^*$  inalterados;
16 |   end
17 |   Execute a seleção de indivíduos que serão os pais da próxima geração;
18 |   Execute a reprodução entre os pais e gere novos descendentes;
19 |   Execute a mutação com probabilidade  $p$ ;
20 |   Atualize os indivíduos da próxima geração;;
21 end
22 return  $y_{mp}^*$ 
```

A representação de possíveis soluções no espaço de busca determina a estrutura cromossômica *i.e.*, a estrutura de um indivíduo. A estrutura proposta nesta pesquisa reflete as posições possíveis das BTSs (dimensão m) e respectivas potências de transmissão selecionadas para cada nó de acesso (dimensão p). Portanto, foi constituído de uma matriz $Y_{M \times P}$ com suas posições ocupadas por genes binários, 0's ou 1's. Cada gene definido como 1 representa a instalação de uma BTS na posição m desse gene e com o poder de transmissão p .

A função de aptidão é o mecanismo pelo qual a adaptabilidade de um cromossomo ou indivíduo é avaliada. Neste contexto, a função *fitness* ($BFit$) consistiu em uma implementação da função objetivo (Equação 4.12) e das restrições 4.1, 4.2 e 4.4 modeladas na Subseção 4.3. As restrições 4.8, 4.9 e 4.10 foram garantidas pela natureza binária do gene. Enquanto as restrições 4.3, 4.5 e 4.6 foram garantidas por um mecanismo de recompensa para situações que respeitam essas restrições e penalidade para os demais casos. Por fim, a restrição 4.7 foi implementada através de um mecanismo de validação para cada alteração genética, seja na instanciação dos indivíduos na primeira geração, ou após a execução do método de reprodução ou de mutação.

Tabela 4.2: Hyperparâmetros da solução M-ALLOCATOR ajustados.

Hyperparametro	Valor
Probabilidade de cruzamento	[0.1 † 0.78 † 1]
Probabilidade de mutação	[0.1 † 0.87 † 1]
Elitismo	{1 ... 2 ... 10}, variando de 1 em 1
Tamanho da população	{10, 20 ... 90 ... 200}, variando de 10 em 10
Número de gerações	{10, 20 ... 60 ... 100}, variando de 10 em 10
Número de pais para reprodução	{2, 4 ... 16 ... 20}, variando de 2 em 2

Para ajustar os hiperparâmetros do AG modelado no M-ALLOCATOR, foi utilizada a biblioteca Hyperas [39]. A Tabela 4.2 apresenta o conjunto de hiperparâmetros analisados que constituem o AG, no qual os melhores valores encontrados estão destacados em negrito. Esses valores foram configurados nos respectivos hiperparâmetros da nossa solução meta-heurística.

A literatura [40, 41, 42, 38] cita algumas maneiras diferentes de implementar os métodos de seleção, reprodução e mutação de um Algoritmo Genético. Portanto, para um ajuste completo da solução M-ALLOCATOR, foi realizada uma análise desses diversos métodos conforme apresentado no capítulo seguinte, mais especificamente na Seção 5.2.

4.5 Considerações Parciais

Este capítulo apresentou as soluções de otimização propostas para o SAD do CCOp Mv. Além de ter fundamentado o modelo do sistema de apoio à decisão do CCOp Mv e definido o problema para determinar o posicionamento e configuração de suas BTSs. As soluções foram avaliadas em comparação com uma heurística do problema e sob os cenários de emprego do CCOp Mv em meio a uma operação de resgate às vítimas da tragédia de Brumadinho-MG conforme apresentado no próximo capítulo.

Capítulo 5

Resultados

Este capítulo avalia o desempenho das soluções de otimização propostas E-ALLOCATOR e M-ALLOCATOR, comparando-as com uma heurística de alocação. Os cenários modelados, as configurações dos experimentos e os resultados alcançados serão apresentados a seguir.

5.1 Cenários Modelados

Os cenários modelados para avaliação das soluções propostas foram baseados na tragédia de Brumadinho-MG. São cenários que ilustram a utilização do CCOp Mv em apoio a uma operação de resgate às vítimas do rompimento da barragem da mina Córrego do Feijão. Ocorrido em 25 de janeiro de 2019, o rompimento da barragem foi o acidente de trabalho mais significativo no Brasil em termos de perda de vidas humanas e o segundo maior desastre industrial do século.

A área de atuação das equipes de resgate e apoio dos veículos do CCOp Mv é apresentada na Figura 5.1. Os cenários têm uma extensão de 6.090 metros de comprimento (longitude) por 4.872 metros de largura (latitude), o que equivale a uma área de cerca de 30 km^2 . É delimitado pelos pontos de coordenadas $(-20.115437, -44.16269)$, $(-20.159446, -44.16269)$, $(-20.159446, -44.10444)$, $(-20.115437, -44.10444)$ e subdividido em setores. Os setores são identificados em linhas i e colunas j . Onde $i \in \{1, 2, 3, \dots, I\}$ e $j \in \{1, 2, 3, \dots, J\}$, onde I é o cardinal de conjunto que divide longitudinalmente e J é o cardinal do conjunto que divide o cenário latitudinalmente. O nome, as dimensões dos cenários e seus respectivos setores são apresentados na Tabela 5.1.

Devido às características do terreno, nem todos os setores podem ter BTSs implantados. Como são transportadas por veículos, utilizamos as rotas rodoviárias como referência para limitar o posicionamento das BTSs, conforme ilustrado na Figura 5.2. Ressalta-se que essas limitações podem ser decorrentes de outros motivos, como relevos muito íngremes,

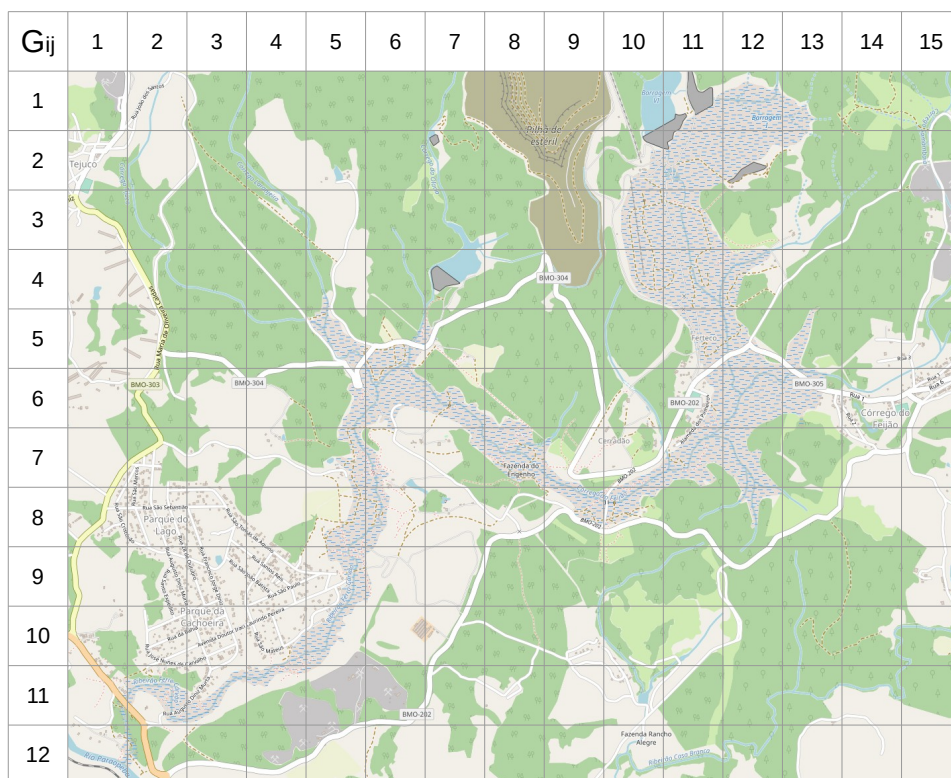


Figura 5.1: Área da tragédia e de atuação das equipes de resgate.
(Fonte: o autor)

Tabela 5.1: Dimensões dos cenários propostos.

Cenário	I	J	Dimensões do setor
Brum1215	12	15	405m x 405m
Brum2025	20	25	243m x 243m
Brum2430	24	30	203m x 203m
Brum3645	36	45	135m x 135m

rios, vegetação muito densa, ou outros fatores. Essas restrições foram consolidadas na matriz binária M_{ij} onde os setores marcados com o valor 1 significam que uma BTS pode ser instalada e 0 caso contrário.

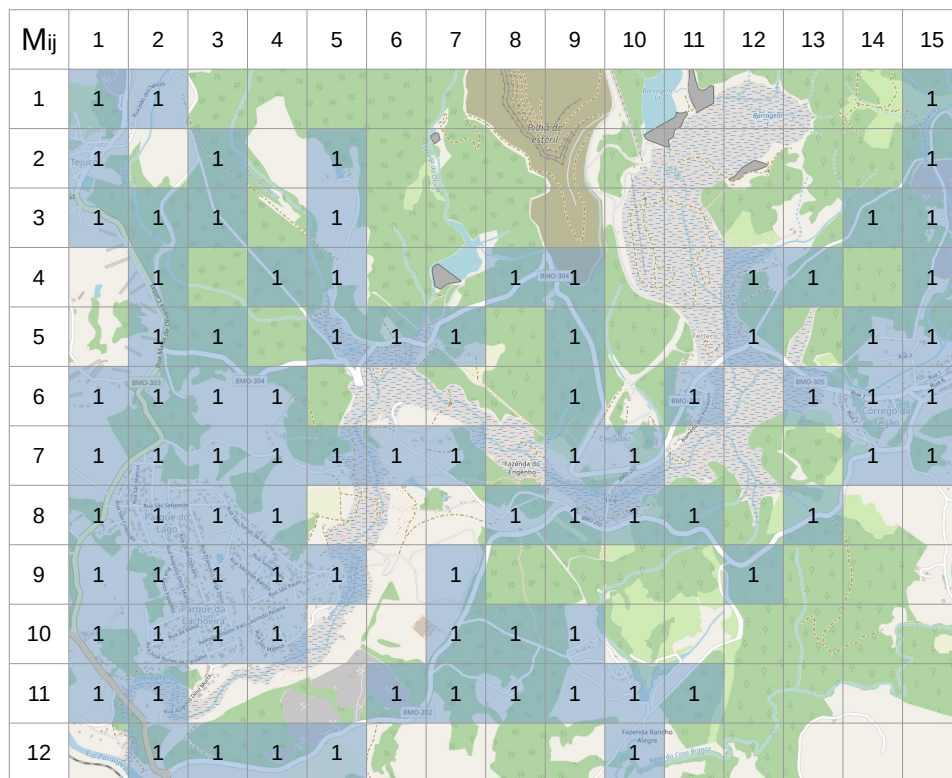


Figura 5.2: Locais para implantação das BTSs.
(Fonte: o autor)

Os UEs precisam estar cobertos para apoiar as comunicações durante a operação de resgate das vítimas da tragédia. Para isso, eles são distribuídos pelo cenário, e suas localizações são consolidadas nos setores em que foram alocados. Essa alocação é determinada pelas autoridades que coordenam as operações de resgate em uma operação real. Para esta pesquisa, 200 socorristas foram distribuídos ao longo das margens do Córrego do Feijão, região atingida pela lama da barragem. A partir do exposto, o posicionamento dos UEs é representado pela matriz N_{ij} , conforme Figura 5.3, onde n representa o número de usuários em um setor.

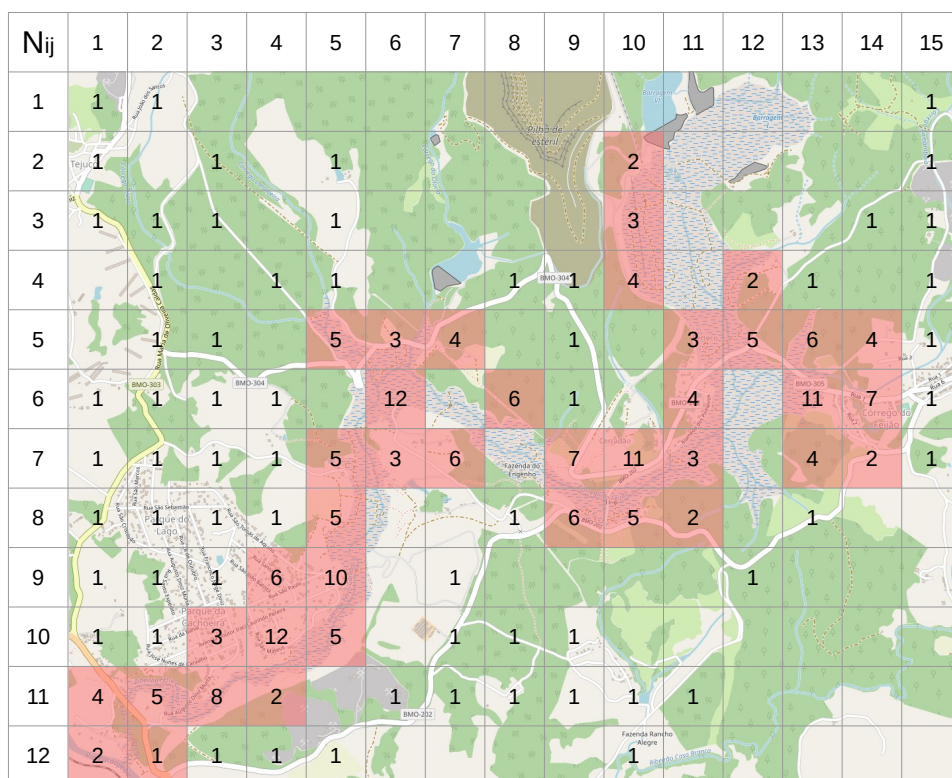


Figura 5.3: Posição dos clientes do sistema ou UEs.
(Fonte: o autor)

Cada BTS entrega uma relação sinal-ruído SNR diretamente relacionada a modelos empíricos de perda de caminho, desvanecimento rápido e desvanecimento lento, condicionados às características do relevo e vegetação de Brumadinho, a existência ou não de LOS, além da distância entre BTSs e UEs. Como resultado, criando uma função de conexão ζ baseada na posição de cada elemento conectado $\zeta(m, p, n) \in \mathbb{Z}$ em que $m \in \mathcal{M}$, $p \in \mathcal{P}$ e $n \in \mathcal{N}$. Iterando todas as BTSs m e todos os UEs n obtém-se uma matriz $S \in \mathbb{Z}_{G \times G}$ que expressa de forma discretizada a força do sinal obtido pela relação entre as BTSs e UEs, como visto na Figura 5.4. A função ζ é baseada na modelagem do cenário de simulação *Rural Macro-Cell* (RMa) [30]. Sua escolha justifica-se ao levar em consideração que as características do terreno delimitadas pela área acima apresentada estão em conformidade com as restrições de emprego especificadas para o cenário RMa e por se tratar de um cenário testado e consolidado pela literatura e pelo 3GPP.

S _m		S _n															
		2,10	3,10	4,10	4,12	5,5	5,6	.	.	.	11,1	11,2	11,3	11,4	12,1	12,2	
1	S _{m,p,n}	2,10	3,10	4,10	4,12	5,5	5,6	.	.	.	11,1	11,2	11,3	11,4	12,1	12,2	
1	1	1,1	0	0	0	0	1	1	.	.	.	0	0	0	0	0	
1	1,1	1,2	0	0	0	0	1	2	.	.	.	0	0	0	0	0	
2	1,15	1,15	1	1	1	2	0	0	.	.	.	0	0	0	0	0	
2	2,1	2,1	0	0	0	0	1	1	.	.	.	0	0	0	0	0	
2	2,3	2,3	0	1	1	0	3	2	.	.	.	0	0	0	0	0	
.	
.	
12	
12	12,3	12,3	0	0	0	0	0	0	.	.	.	3	3	2	2	3	
12	12,4	12,4	0	0	0	0	0	1	.	.	.	3	2	2	2	1	
12	12,5	12,5	0	0	0	0	1	0	.	.	.	2	2	3	2	1	
12	12,10	12,10	0	0	1	1	1	1	.	.	.	0	0	0	1	0	

Figura 5.4: Matrizes de Adjacências entre as posições de BTSs M_{ij} e os UEs em N_{ij} para cada potência de transmissão p .

(Fonte: o autor)

É fundamental ressaltar que os valores da função de conexão $\zeta(m, p, n)$ foram definidos a partir das categorias de potência de recepção apresentadas em [43]. Esta categorização usa o padrão *Reference Signal Received Power* (RSRP). É um tipo de medição do Indicador de Força do Sinal Recebido, do inglês *Received Signal Strength Indication* (RSSI). A

potência do sinal de referência 4G/LTE se espalha por toda a largura de banda e banda estreita. Esses valores consideram que os UEs possuem antenas de recepção com ganho de 0dBi, como a maioria dos smartphones vendidos hoje. Assim, a Força do Sinal Prevista (FSP) pelos modelos em RMa foi discretizada em quatro níveis para atribuição à matriz S da seguinte forma:

$$\zeta(m, p, n) = \begin{cases} 3, & \text{se } FSP \geq -80 \text{ dBm;} \\ 2, & \text{se } -80 \text{ dBm} < FSP \leq -90 \text{ dBm;} \\ 1, & \text{se } -90 \text{ dBm} < FSP \leq -100 \text{ dBm;} \\ 0, & \text{caso contrário.} \end{cases}$$

Tabela 5.2 apresenta o conjunto de parâmetros usados nos modelos de propagação 3GPP RMa [30, 36]. Junto com esses parâmetros, a probabilidade de linha de visada (P_{LOS}) definida em [30] foi usada para gerar as matrizes de peso e conectividade que são usadas como entrada no processo de otimização para gerar os resultados. O conjunto \mathcal{P} de valores de potência de transmissão avaliados que compõem cada uma das matrizes de adjacência apresentadas na Figura 5.4 são um subconjunto do intervalo avaliado em [15] ($TxPower$). Portanto, $\mathcal{P} \subset TxPower$. Onde $\mathcal{P} = \{20, 25, 30, 35, 40\}$ e $TxPower = \{5, 10, 15, 20, 25, 30, 35, 40\}$, todos os valores em dBm.

Tabela 5.2: Parâmetros utilizados nos cenários modelados.

Parâmetro	Valor
Altura das BTSs	10m
Altura dos UEs	1,5m
Altura média das construções	5m
Largura média das estradas	20m
Potência de transmissão (\mathcal{P})	20, 25, 30, 35 e 40 dBm
Ganho das antenas de transmissão	13dBi
Ganho das antenas de recepção	0dBi
Frequência do canal	700MHz
Dimensões dos cenários IxJ	12x15, 20x25, 24x30 e 36x45
Iterações	30

As seguintes medidas de desempenho foram utilizadas para avaliar as soluções propostas: tempo de processamento, grau de sobreposição para cada consenso de cobertura, número de BTSs implantadas, número de UEs atendidos, área de cobertura, nível de interferência e Desvio Percentual Relativo (DPR). As simulações foram executadas em Máquinas Virtuais, do inglês *Virtual Machine* (VM), instanciadas no ambiente Google Cloud Platform. Cada instância criada era do tipo n2d-standard-2 e possuía as seguintes

configurações: 2 núcleos de processamento da arquitetura AMD Rome, 8 GB de RAM, 10 GB de HDD, sistema operacional Ubuntu 18.04 LTS bionic, região: us-central1 (Iowa) e zona: us-central1-c.

5.2 Avaliação do M-ALLOCATOR

Os experimentos foram agrupados por fatores a serem avaliados. Para isso, foram realizados três grupos de testes: (i) com variação dos métodos de seleção, (ii) com variação dos métodos de reprodução e (iii) com variação dos métodos de mutação. Além do ajuste dos hiperparâmetros, foram avaliados os resultados obtidos pelos métodos de seleção, reprodução e mutação. Na literatura, foram identificados seis principais mecanismos de seleção, os quais foram analisados neste trabalho: (i) Estado Estável (EE); (ii) Roleta (R); (iii) Estocástico (E); (iv) Truncamento (Tr); (v) Aleatório (A); e (vi) Torneio (To). Em relação aos métodos de reprodução, os métodos de troca genética avaliados foram: (i) Ponto Simples (PS); (ii) Dois Pontos (DP); (iii) Uniforme (U); e (iv) Espalhamento (Es). Na fase de mutação, três métodos foram avaliados: (i) Troca (T); (ii) Inversão (I); e (iii) Embaralhamento (Em).

Na Figura 5.5, é apresentada a avaliação de desempenho das soluções otimizadas com a variação dos métodos de seleção. Com base no resultado ótimo obtido pelo E-ALLOCATOR, pode-se observar que o tempo de convergência do M-ALLOCATOR com o método EE tem maior velocidade de aproximação, seguido por Tr e To (Figura 5.5a). Isso ocorre porque o método EE retira os piores indivíduos e os substitui por outros indivíduos gerados, tornando o processo mais adequado à lista que compõe os candidatos. A melhor métrica de aptidão confirma isso (Figure 5.5b) e o tempo de processamento (Figure 5.5c) que, além de ter um intervalo interquartil menor, tem uma mediana um pouco melhor quando comparado a outros métodos de seleção do M-ALLOCATOR.




Figura 5.5: Impacto de desempenho com a variação dos métodos de seleção.
(Fonte: o autor)

Após explorar os métodos de seleção da solução M-ALLOCATOR, exploramos os métodos de reprodução, conforme mostrado na Figura 5.6. Na Figura 5.6a, observa-se que independente da quantidade de gerações, o M-ALLOCATOR com o método PS é o método de reprodução mais eficiente, baseado na solução ótima (ou seja, E-ALLOCATOR). Dado que o PS explora regiões próximas aos indivíduos, isso faz sentido já que agrega novas informações a cada geração. Como resultado, há uma melhor adequação (Figura 5.6b) com um menor tempo de processamento (Figura 5.6c).




Figura 5.6: Impacto de desempenho com a variação dos métodos de reprodução. (Fonte: o autor)

Em relação aos métodos de mutação (Figura 5.7), observa-se que há uma convergência mais rápida do M-ALLOCATOR quando se utiliza o método Em (Figura 5.7a), aproximando-se da solução à medida que o número de gerações aumenta. Além disso, vale a pena notar que não há diferença na métrica de aptidão (Figura 5.7b) e tempo de processamento (Figura 5.7) ao usar os métodos Em e I.




Figura 5.7: Impacto de desempenho com a variação dos métodos de mutação. (Fonte: o autor)

5.3 Avaliação de desempenho das soluções propostas

As duas soluções propostas (E-ALLOCATOR e M-ALLOCATOR) foram comparadas com uma solução heurística para avaliar o problema de otimização. Nesta última, as posições

dos UEs são agrupadas por similaridade de suas distâncias euclidianas. Em seguida, as posições de implantação das BTSs são definidas pelo setor de M_{ij} mais próximo de cada cluster encontrado. Esta heurística define as posições das BTSs e utiliza a potência média de transmissão entre as disponíveis na avaliação *i.e.*, 30 dBm. Como essa heurística não determina a quantidade de BTSs a ser implantada, essa quantidade foi herdada daquela definida pela solução E-ALLOCATOR para uma comparação mais justa. Os cenários e o consenso de cobertura agruparam os resultados apenas para fins de comparação. Devido a isso, no eixo horizontal de todos os gráficos, são exibidos os consensos de cobertura discretizados nos valores de 80%, 90%, 95%, 98% e 100%. Foram conduzidos 30 experimentos para cada grupo de resultados com intervalo de confiança de 95%.

A Figura 5.8 apresenta o número de BTSs resultante do processo de otimização das soluções E-ALLOCATOR e M-ALLOCATOR. Os resultados da heurística do problema não são exibidos porque foram herdados dos resultados obtidos pelo E-ALLOCATOR. Fica evidente nesta comparação que a solução M-ALLOCATOR é mais econômica ao empregar um número menor de veículos do CCOp Mv em todos os cenários e consensos de cobertura, exceto para o caso do cenário Brum1215 no consenso de cobertura de 100% em que o E-ALLOCATOR sempre emprega quatro veículos enquanto a solução meta-heurística tem uma média ligeiramente superior. No entanto, a análise de economia de recursos não deve ocorrer isoladamente. Deve-se levar em consideração a potência total de transmissão gasta em cada caso, apresentada na Figura 5.9. Estes resultados (5.9) confirmam o resultado anterior (5.8) ao demonstrar que, na maioria dos casos, a solução M-ALLOCATOR supera tanto a solução heurística quanto a exata por apresentar os menores valores relativos.




Figura 5.8: Número de BTSs (veículos do CCOp Mv) implantados.
(Fonte: o autor)

Em termos de qualidade das soluções, a Figura 5.10 apresenta o comportamento das soluções em relação aos dois objetivos de otimização. Ao correlacionar o consenso de cobertura (no eixo horizontal), que expressa a maximização da cobertura para UEs, com a interferência causada pela sobreposição dos sinais das BTSs implantadas (no eixo vertical), observamos o ótimo de Pareto nos resultados da solução E-ALLOCATOR. Isso se deve à




Figura 5.9: Energia despendida com a Potência de Transmissão Total.
(Fonte: o autor)

solução exata que cobre todo o espaço de pesquisa e garante resultados ótimos. Devido a isso, o E-ALLOCATOR tem o menor grau de sobreposição de valores. Essa análise também destaca que, embora o M-ALLOCATOR não garanta soluções ótimas de Pareto, ele entrega resultados muito próximos aos obtidos pela solução exata. Tendo obtido valores de DPR consolidados para todos os cenários e consenso de cobertura com médias de 26,22% e desvio padrão de 9,29% e sendo praticamente constantes, conforme Figura 5.11. Dessa forma, fica comprovada a superioridade da qualidade dos resultados obtidos pelas duas soluções propostas sobre a heurística.




Figura 5.10: Grau de Sobreposição representando a interferência da sobreposição dos sinais das BTSs implantadas sobre os setores de UEs N_{ij} .
(Fonte: o autor)

Inicialmente, podemos pensar que as melhores soluções entregariam uma área de cobertura maior em km^2 . No entanto, conforme mostrado na Figura 5.12, a área coberta é, em praticamente todos os casos, maior nos resultados da heurística, seguida pelos resultados da solução M-ALLOCATOR e, por fim, pelos resultados da solução E-ALOCADOR. O que ocorre na verdade é que os resultados expressos na Figura 5.12 demonstram exatamente o sinal desperdiçado fornecido pelas soluções M-ALLOCATOR e pelas heurísticas. Isso porque o que determina a qualidade do serviço para os UEs do sistema é o valor do consenso de cobertura. Ele atua como uma restrição de otimização, garantindo um número mínimo de clientes do sistema atendidos pelas soluções E-ALLOCATOR e M-ALLOCATOR. Do exposto, pode-se concluir que a solução E-ALLOCATOR é mais




Figura 5.11: Desvio Percentual Relativo (DPR) do ótimo de Pareto obtido pela solução E-ALLOCATOR.

(Fonte: o autor)

seletiva nas escolhas de posições de implantação, quantidade e configurações das BTSs do CCOp Mv. Ela é seguida pela solução M-ALLOCATOR, e ambas se mostram superiores, em termos de seletividade, em comparação aos resultados alcançados pela heurística.




Figura 5.12: Área Coberta expressa pela soma das áreas dos setores cobertos por pelo menos uma BTS.

(Fonte: o autor)

A superioridade dos resultados alcançados pelas soluções propostas, em termos de qualidade e de economia de recursos, foi comprovada; no entanto, está associada a um custo de processamento muito superior ao da heurística, o que se reflete diretamente no tempo de processamento de cada uma das soluções propostas. A Figure 5.13 revela que a solução E-ALLOCATOR é a mais sensível ao aumento da carga de trabalho, pois apresenta um aumento exponencial (ressalta-se que a escala de tempo apresentada é logarítmica). Isso se deve à complexidade das soluções baseadas no algoritmo *Branch and Bound* ser da ordem de $O(n^2)$ conforme demonstrado em [44]. Já a solução M-ALLOCATOR apresentou um aumento linear. Este comportamento é entendido uma vez que esta solução avalia a qualidade de suas soluções de forma estocástica e mantém fixo o número de gerações que irá analisar. O tempo de processamento aumenta em M-ALLOCATOR em cada cenário devido à crescente complexidade das avaliações das soluções o que justifica a linearidade do aumento de tempo de processamento. Devido a um número mais significativo de nós no grafo do sistema, o número de comparações para obter o grau de adaptação de cada solução

(ou seja, o peso das arestas resultantes das associações entre BTSs e UEs) avaliada é proporcionalmente maior. A heurística praticamente não sofre com o aumento da carga de trabalho e continua a fornecer resultados instantaneamente. O comportamento heurístico é justificado pela baixa carga de processamento que realiza, pois não avalia as matrizes de pesos e de conectividade para decidir onde implantar as BTSs.




Figura 5.13: Impacto do consenso de cobertura e das dimensões dos cenários sobre o tempo de processamento.

(Fonte: o autor)

De uma análise holística cabe destacar que da definição do problema e entre as restrições apresentadas em sua modelagem, observou-se que a restrição 4.6 gerou maior impacto nos resultados obtidos. Isso se deve à restrição que impõe aos nós de acesso de serem distribuídos em clusters. Isso aumenta a interferência co-canal entre as células e reduz a área de cobertura do sistema e o número de clientes atendidos.

Por fim, vale ressaltar que o E-ALLOCATOR demonstrou ser adequado para cenários com baixa carga de trabalho, enquanto o M-ALLOCATOR, adequado para cenários com altas cargas de trabalho. Além desse aspecto, o mecanismo de otimização M-ALLOCATOR demonstrou fornecer soluções quase ótimas (com pouco DPR em relação ao ótimo de Pareto) dentro do tempo computacional adequado para todas as instâncias do problema.

Capítulo 6

Conclusões

Esta dissertação explorou o problema de localização de cobertura máxima com mínima interferência do Centro de Coordenação de Operações Móveis (CCOp Mv) que visa apoiar o comando operacional do Exército Brasileiro. Diante desse problema, esta pesquisa investigou as questões de emprego do CCOp Mv e que tem impacto direto na eficiência espectral da rede de acesso rádio do sistema 4G/LTE do CCOp Mv. Por isso, as principais questões exploradas foram:

- Qual o número de BTSs utilizar para uma determinada demanda de emprego?
- Qual a localização destes veículos?
- Quais critérios utilizar para a definição das posições das BTSs?
- Quais os parâmetros devem ser configurados em cada BTS?

Ressalta-se a importância destas respostas pois elas sempre serão necessárias aos militares que irão operar o CCOp Mv. Com esta motivação, os objetivos propostos para esta pesquisa e que nortearam a busca pelas respostas a essas questões foram os dois objetivos de otimização apresentados na Seção 4.3 do Capítulo 4: (i) maximização da área de cobertura; e (ii) minimização da interferência entre as BTSs.

Para tanto, esta dissertação propôs um modelo analítico baseado em PLIM, que foi utilizado para modelar duas soluções otimizadas: (i) E-ALLOCATOR; e (ii) M-ALOCADOR. Além de cobrir o maior número de pontos de demanda com o menor número de nós e potências de transmissão ajustadas, ambas as soluções visam reduzir as interferências decorrentes da sobreposição de sinais das BTSs. O objetivo é fornecer a melhor cobertura possível ao empregar o CCOp Mv em operações que exigem comunicação crítica com maior qualidade e economia de recursos.

Para validar a viabilidade das soluções propostas, foram modelados cenários com base na tragédia ocorrida em janeiro de 2019 em Brumadinho-MG. Os resultados demonstra-

ram que o E-ALLOCATOR é adequado para uma baixa carga de trabalho, enquanto o M-ALLOCATOR é mais adequado para cenários com alta carga de trabalho. Ambas as soluções propostas são superiores à heurística apresentada, pois superam-na em termos de qualidade, confiabilidade e economia de recursos. Além disso, os resultados demonstram que o tempo de computação do E-ALLOCATOR aumenta significativamente com o tamanho do problema. Ao mesmo tempo, M-ALLOCATOR fornece soluções quase ótimas dentro do tempo computacional adequado para todas as instâncias.

6.1 Principais Contribuições

A realização desta pesquisa obteve as seguintes contribuições listadas a seguir:

- Uma modelagem analítica do problema de localização e configuração das BTSs do CCOP Mv fundamentada em PLIM em extensão ao MCLP, descrita na Seção 4.2.
- Uma solução de otimização exata, E-ALLOCATOR: Exact - ALLOCATiOn seRvice, apresentada ns Subseção 4.4.1.
- Uma solução de otimização meta-heurística, M-ALLOCATOR: Metaheuristic - ALLOCATiOn seRvice. Esta solução teve todos seus hiperparâmetros e seus métodos ajustados, os primeiros conforme demonstrado na Subseção 4.4.2, já os últimos na Seção 5.2.
- Uma heurística para o problema que enriqueceu as comparações, descrita na Seção 5.3.
- Cenários de avaliação consistentes, reproduzíveis e de fácil extensão para aplicação em pesquisas que demandem alocação geográfica de recursos, sua modelagem foi descrita na Seção 5.1.
- Os estudos iniciais desta pesquisa foram apresentados e publicados no XXVI Workshop de Gerência e Operação de Redes e Serviços (WGRS) do XXXIX Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC 2021) [45].
 - O trabalho publicado no XXVI WGRS foi agraciado com o prêmio de menção honrosa. A codificação gerada encontra-se disponível no repositório criado para divulgação desta pesquisa¹.
- A versão completa desta dissertação foi publicada no IEEE *Transactions on Network and Service Management*, Qualis A2 e fator de impacto 5.91. Esta publicação [46]

¹<https://github.com/eoantunes/AlocacaoDeAntenas>

consistiu de diversas melhorias e consolidou o estado atual da pesquisa apresentada nesta dissertação. Os cenários modelados, a codificação das soluções e das simulações encontram-se disponíveis no repositório deste estágio da pesquisa².

6.2 Trabalhos Futuros

Como trabalhos futuros, sugere-se empregar as soluções de otimização, aqui propostas e apresentadas, como base para o desenvolvimento de um mecanismo de alocação dinâmica. Tal mecanismo poderá se constituir de um módulo do SAD do Centro de Coordenação de Operações Móveis que objetivará auxiliar os tomadores de decisão na escolha das melhores estratégias de alocação dinâmica dos veículos do CCOp Mv. Neste trabalho, as BTSs se moveram para otimização e melhoria de desempenho da rede, enquanto os UEs permaneciam fixos numa única posição. Porém, numa operação militar real, com o passar do tempo os militares estarão se movendo ao longo de sua área de atuação, evidenciando a necessidade de reposicionamento das viaturas que transportam as BTSs do CCOp Mv.

Diante deste novo desafio novos questionamentos precisarão ser analisados. Entre os quais citam-se:

- Quando mover as viaturas do CCOp Mv?
- Elas devem se mover todas de uma única vez ou de forma cadenciada?
- Como cadenciar a movimentação das viaturas?
- Qual impacto no desempenho da rede em cada política de alocação dinâmica proposta?
- Haverá indisponibilidade da rede?
- Quantas e quais BTSs serão empregadas no próximo instante?
- Existem viaturas reservas para utilizar no instante seguinte?

Estas questões precisarão ser pensadas antes de empregar o CCOp Mv em operações reais. Tais ações são necessárias de modo a otimizar a utilização de seus recursos. Provendo não apenas economia energética no deslocamento das viaturas e na redução da potência de transmissão total do sistema, como também melhoria na eficácia da cobertura da rede e em seu desempenho com a maximização do *throughput* total.

²<https://github.com/eoantunes/TNSM>

Referências

- [1] Mathar, Rudolf e Thomas Niessen: *Optimum positioning of base stations for cellular radio networks*. *Wireless Networks*, 6(6):421–428, 2000. 1
- [2] Rappaport, Theodore S *et al.*: *Wireless communications: principles and practice*, volume 2. Prentice Hall PTR New Jersey, 2002. 1, 21
- [3] Costa, Vinícius Oliveira: *Alocação de antenas para rede celular de 4G utilizando algoritmos meméticos*. Dissertação de Mestrado, 2016. 1, 2, 29, 31
- [4] Atta, Soumen, Priya Ranjan Sinha Mahapatra e Anirban Mukhopadhyay: *Solving maximal covering location problem using genetic algorithm with local refinement*. *Soft Computing*, 22(12):3891–3906, 2018. 1, 2, 29, 31
- [5] Bagherinejad, Jafar e Mahnaz Shoeib: *Dynamic capacitated maximal covering location problem by considering dynamic capacity*. *International Journal of Industrial Engineering Computations*, 9(2):249–264, 2018. 1, 2, 29, 31
- [6] Seda, Pavel, Milos Seda e Jiri Hosek: *On mathematical modelling of automated coverage optimization in wireless 5g and beyond deployments*. *Applied Sciences*, 10(24):8853, 2020. 1, 2, 30, 31
- [7] Yang, Pei, Yiyong Xiao, Yue Zhang, Shenghan Zhou, Jun Yang e Yuchun Xu: *The continuous maximal covering location problem in large-scale natural disaster rescue scenes*. *Computers & Industrial Engineering*, 146:106608, 2020. 1, 2, 30, 31
- [8] Gazani, M e S Niaki: *The capacitated maximal covering location problem with heterogeneous facilities and vehicles and different setup costs: An effective heuristic approach*. *International Journal of Industrial Engineering Computations*, 12(1):79–90, 2021. 1, 2, 30, 31
- [9] Meneguette, Rodolfo, Robson De Grande, Jo Ueyama, Geraldo P Rocha Filho e Edmundo Madeira: *Vehicular edge computing: Architecture, resource management, security, and challenges*. *ACM Computing Surveys (CSUR)*, 55(1):1–46, 2021. 1
- [10] Rocha Filho, Geraldo P, Rodolfo I Meneguette, José R Torres Neto, Alan Valejo, Li Weigang, Jó Ueyama, Gustavo Pessin e Leandro A Villas: *Enhancing intelligence in traffic management systems to aid in vehicle traffic congestion problems in smart cities*. *Ad Hoc Networks*, 107:102265, 2020. 1

- [11] Alizadeh, Roghayyeh, Tatsushi Nishi, Jafar Bagherinejad e Mahdi Bashiri: *Multi-period maximal covering location problem with capacitated facilities and modules for natural disaster relief services*. Applied Sciences, 11(1):397, 2021. 1, 2, 30, 31
- [12] Church, Richard e Charles ReVelle: *The maximal covering location problem*. Em *Papers of the regional science association*, volume 32, páginas 101–118. Springer-Verlag, 1974. 2, 29
- [13] Mehboob, Usama, Junaid Qadir, Salman Ali e Athanasios Vasilakos: *Genetic algorithms in wireless networking: techniques, applications, and issues*. Soft Computing, 20(6):2467–2501, 2016. 2
- [14] Vallejo-Mora, Ana Belen, Matías Toril, Salvador Luna-Ramírez, Miguel Regueira e Salvador Pedraza: *Analytical model for estimating the impact of changing the nominal power parameter in lte*. Mobile Information Systems, 2018, 2018. 2, 31
- [15] Grochla, Krzysztof e Mariusz Slabicki: *Transmit power optimisation in cellular networks with nomadic base stations*. IET Communications, 13(18):3068–3074, 2019. 2, 31, 50
- [16] Premkumar, Manoharan, Pradeep Jangir, Balan Santhosh Kumar, Ravichandran Sowmya, Hassan Haes Alhelou, Laith Abualigah, Ali Riza Yildiz e Seyedali Mirjalili: *A new arithmetic optimization algorithm for solving real-world multiobjective cec-2021 constrained optimization problems: Diversity analysis and validations*. IEEE Access, 9:84263–84295, 2021. 2
- [17] Kumar, Sumit, Pradeep Jangir, Ghanshyam G Tejani, Manoharan Premkumar e Hassan Haes Alhelou: *Mopgo: A new physics-based multi-objective plasma generation optimizer for solving structural optimization problems*. IEEE Access, 9:84982–85016, 2021. 2
- [18] Jain, Raj: *The art of computer systems performance analysis: Techniques*. John wiley & Sons, 2010. 3
- [19] Sobrapo: *O que é pesquisa operacional?* <https://www.sobrapo.org.br/o-que-e-pesquisa-operacional>, 2021. acessado em 12/09/2021. 4, 5
- [20] Barbosa, Marcos Antonio e Ricardo Alexandre D Zanardini: *Iniciação à pesquisa operacional no ambiente de gestão*. InterSaberes, 3ª edição, 2015. 5, 6, 8
- [21] Lachtermarcher, G.: *Pesquisa Operacional na tomada de decisões: modelagem em Excel. 4ª Edição. Rio de Janeiro*. Elsevier, 2009. 5, 6
- [22] Taha, Hamdy A: *Pesquisa Operacional. 8ª Edição*. São Paulo: Pearson Prentice Hall, 2008. 6
- [23] Andrade, E. L.: *Introdução à Pesquisa Operacional: métodos e modelos para análise de decisões. 4ª Edição. Rio de Janeiro*. LTC, 2009. 6
- [24] Arenales, Marcos, Vinícius Armentano *et al.*: *Pesquisa operacional*. Elsevier Brasil, 2015, ISBN 978-85-352-7161-4. 7, 8

- [25] Scholarpedia: *Metaheuristics*. <http://scholarpedia.org/article/Metaheuristics>, 2021. acessado em 12/09/2021. 9
- [26] Collette, Yann e Patrick Siarry: *Multiobjective optimization: principles and case studies*. Springer Science & Business Media, 2004, ISBN 3-540-40182-2. 11, 13, 17, 18, 19
- [27] Ehrgott, Matthias e Harold P Benson: *Multicriteria Optimization*. Springer North-Holland, 2007, ISBN 978-3-540-27659-3. 12, 17, 18, 19, 20
- [28] Coello, Carlos A Coello, Gary B Lamont, David A Van Veldhuizen *et al.*: *Evolutionary algorithms for solving multi-objective problems*, volume 5. Springer, 2007, ISBN 978-0-387-33254-3. 17, 19, 20
- [29] Sverzut, José Umberto: *Redes GSM, GPRS, EDGE e UMTS: Evolução a Caminho da Quarta Geração (4G)*. 4^a Edição. São Paulo. Editora Saraiva, 2016, ISBN 978-85-365-2206-7. 20, 21, 24
- [30] 3GPP: *Technical report tr-36.814 v 9.2.0*. https://www.3gpp.org/ftp/Specs/archive/36_series/36.814/36814-920.zip, 2017. acessado em 18/06/2021. 22, 34, 49, 50
- [31] Seybold, John S: *Introduction to RF propagation*. John Wiley & Sons, 2005, ISBN 978-0-471-65596-1. 22
- [32] Balanis, Constantine A: *Antenna theory: analysis and design*. John wiley & Sons, 2015, ISBN 978-0-471-59268-4. 23
- [33] Brasileiro, Exército: *Programa Proteger: Proteção da Sociedade*. <http://www.epex.eb.mil.br/index.php/proteger>, 2021. acessado em 04/05/2021. 28, 33
- [34] García, Antonio J, Víctor Buenestado, Matías Toril, Salvador Luna-Ramírez e JM Ruiz: *A geometric method for estimating the nominal cell range in cellular networks*. Mobile Information Systems, 2018, 2018. 31
- [35] Ghosh, Arijeet, Iti Saha Misra e Anindita Kundu: *Coverage and rate analysis in two-tier heterogeneous networks under suburban and urban scenarios*. Transactions on Emerging Telecommunications Technologies, 30(12):e3648, 2019. 31
- [36] 3GPP: *Technical report tr-36.872 v 12.1.0*. https://www.3gpp.org/ftp/Specs/archive/36_series/36.872/36872-c10.zip, 2013. acessado em 18/06/2021. 34, 50
- [37] OR-Tools, Google: *Project description: ortools 9.3.10497*. <https://pypi.org/project/ortools/>, 2021. acessado em 22/09/2021. 41
- [38] Gad, Ahmed Fawzy: *Pygad: An intuitive genetic algorithm python library*, 2021. 42, 44
- [39] Pumperla, Max: *Hyperas*. <https://github.com/maxpumperla/hyperas>, 2021. acessado em 07/11/2021. 44

- [40] Bies, Robert R, Matthew F Muldoon, Bruce G Pollock, Steven Manuck, Gwenn Smith e Mark E Sale: *A genetic algorithm-based, hybrid machine learning approach to model selection*. Journal of pharmacokinetics and pharmacodynamics, 33(2):195, 2006. 44
- [41] Cha, Sung Hyuk e Charles C Tappert: *A genetic algorithm for constructing compact binary decision trees*. Journal of pattern recognition research, 4(1):1–13, 2009. 44
- [42] Sivanandam, S.N. e S.N. Deepa: *Principles of soft computing*. John Wiley & Sons, 2013, ISBN 978-1-118-54680-2. 44
- [43] Telkonika: *Mobile signal strength recommendations*. https://wiki.teltonika-networks.com/view/Mobile_Signal_Strength_Recommendations, 2020. acessado em 28/11/2021. 49
- [44] Rust, Ronaldo: *Um Algoritmo Branch and Bound para resolução de problemas de localização capacitados*. Tese de Doutorado, Universidade Federal do Rio de Janeiro, 1983. 55
- [45] Antunes, Emerson de O, Marcos F Caetano, Marcelo A Marotta, Aleteia Araujo, Lucas Bondan, Rodolfo I Meneguette e Geraldo P Rocha Filho: *Soluções Otimizadas para o Problema de Localização de Máxima Cobertura em Redes Militarizadas 4G/LTE*. Em *Anais do XXVI Workshop de Gerência e Operação de Redes e Serviços*, páginas 152–165. SBC, 2021. 58
- [46] Antunes, Emerson de O., Marcos F. Caetano, Marcelo A. Marotta, Aleteia Araujo, Lucas Bondan, Rodolfo I. Meneguette e Geraldo P. Rocha Filho: *Optimized solutions for deploying a militarized 4g/lte network with maximum coverage and minimum interference*. IEEE Transactions on Network and Service Management, páginas 1–12, 2022. 58